



TUGAS AKHIR - SS141501

**PEMILIHAN INPUT DENGAN *RANDOM FOREST*
PADA MODEL *TIME SERIES REGRESSION* DAN
DOUBLE SEASONAL ARIMA UNTUK PERAMALAN
DATA PEMAKAIAN BEBAN LISTRIK JANGKA PENDEK**

**NAYSILA SINTYANINGRUM
NRP 1313 100 025**

**Dosen Pembimbing
Dr. Suhartono
Dr. rer. pol. Dedy Dwi Prastyo, S.Si.,M.Si.**

**PROGRAM STUDI S1
JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



TUGAS AKHIR - SS141501

**PEMILIHAN INPUT DENGAN *RANDOM FOREST*
PADA MODEL *TIME SERIES REGRESSION* DAN
DOUBLE SEASONAL ARIMA UNTUK PERAMALAN
DATA PEMAKAIAN BEBAN LISTRIK JANGKA PENDEK**

**NAYSILA SINTYANINGRUM
NRP 1313 100 025**

**Dosen Pembimbing
Dr. Suhartono
Dr. rer. pol. Dedy Dwi Prastyo, S.Si.,M.Si.**

**PROGRAM STUDI S1
JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



FINAL PROJECT - SS141501

***INPUT SELECTION USING RANDOM FOREST
ON TIME SERIES REGRESSION AND DOUBLE
SEASONAL ARIMA MODEL FOR FORECASTING
SHORT-TERM ELECTRICITY LOAD***

NAYSILA SINTYANINGRUM
NRP 1313 100 025

Supervisor
Dr. Suhartono
Dr. rer. pol. Dedy Dwi Prastyo, S.Si.,M.Si.

UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017

LEMBAR PENGESAHAN

**PEMILIHAN INPUT DENGAN *RANDOM FOREST*
PADA MODEL *TIME SERIES REGRESSION* DAN
DOUBLE SEASONAL ARIMA UNTUK PERAMALAN
DATA PEMAKAIAN BEBAN LISTRIK JANGKA PENDEK**

TUGAS AKHIR

**Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada**

**Program Studi S-1 Jurusan Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember**

Oleh :

**NAYSILA SINTYANINGRUM
NRP 1313 100 025**

Disetujui oleh Pembimbing Tugas Akhir

Dr. Suhartono

NIP. 19710929 199512 1 001

()

Dr. rer. pol. Dedy Dwi P., S.Si, M.Si

NIP. 19831204 200812 1 002

()

Mengetahui

Ketua Jurusan Statistika FMIPA-ITS

Dr. Suhartono

NIP. 19710929 199512 1 001

SURABAYA, JANUARI 2017



PEMILIHAN INPUT DENGAN RANDOM FOREST PADA MODEL TIME SERIES REGRESSION DAN DOUBLE SEASONAL ARIMA UNTUK PERAMALAN DATA PEMAKAIAN BEBAN LISTRIK JANGKA PENDEK

Nama Mahasiswa : Naysila Sintyaningrum
NRP : 1313 100 025
Jurusan : Statistika FMIPA - ITS
Dosen Pembimbing: Dr. Suhartono
Dr. rer. pol. Dedy Dwi Prastyo, S.Si, M.Si

Abstrak

Pemakaian beban listrik untuk menunjang aktivitas masyarakat semakin meningkat. Peningkatan permintaan energi listrik yang tinggi perlu diimbangi dengan ketersediaan pasokan listrik yang memadai. Ketersediaan energi listrik erat kaitannya dengan tinggi rendahnya daya listrik. Apabila pembangkit listrik menghasilkan daya yang terlalu besar maka akan terjadi pemborosan sedangkan jika daya yang dihasilkan terlalu kecil maka mengakibatkan pemadaman listrik secara bergilir. Berdasarkan hal tersebut, peramalan pemakaian beban listrik jangka pendek menjadi sangat penting. Model peramalan yang mempunyai akurasi tinggi sangat sulit didapatkan karena pemilihan variabel input pada model melibatkan lag yang sangat besar. Oleh karena itu dalam penelitian ini akan dibahas mengenai aplikasi metode Random Forest untuk pemilihan input (prediktor) pada model Time Series Regression dan Double Seasonal ARIMA untuk peramalan pemakaian beban listrik jangka pendek. Data yang digunakan merupakan data sekunder pemakaian beban listrik Jawa Timur per-setengah jam pada periode 24 September 2015 hingga 30 September 2016. Penelitian ini diperoleh kesimpulan bahwa peramalan terbaik menggunakan pemilihan input dengan metode Stepwise pada model Time Series Regression.

Kata Kunci : *Beban Listrik, Double Seasonal ARIMA, Time Series Regression, Random Forest.*

INPUT SELECTION USING RANDOM FOREST ON TIME SERIES REGRESSION AND DOUBLE SEASONAL ARIMA MODEL FOR FORECASTING SHORT-TERM ELECTRICITY LOAD

Name : Naysila Sintyaningrum
NRP : 1313 100 025
Department : Statistika FMIPA - ITS
Supervisor : Dr. Suhartono
Dr. rer. pol. Dedy Dwi Prastyo, S.Si, M.Si

Abstract

The use of electrical load to support community activities is increasing. The enhancement of the demand for high electrical energy needs to be balanced with the availability of reliable electricity supply. Availability of electrical energy is closely related to the high and low power. If the power plant produces power that is too large then there would be a waste whereas if the power generated is too small, then it would lead to blackouts of the houses around. Accordingly, the use of forecasting short-term power load becomes very important. Forecasting model has a high accuracy is very difficult to obtain because of the selection of the input variables in the model involve a huge lag. Therefore, in this study there will be a discussion on application of Random Forest method for the selection of input (predictor) on the model Time Series Regression and Double Seasonal ARIMA for forecasting short-term electricity load consumption. The data used is secondary data usage East Java electrical loads per half-an-hour during the period 24 September 2015 to 30 September 2016. This study we concluded that the best forecasting using the input selection with Stepwise method on Time Series Regression model.

Keywords: *Electrical Load, Double Seasonal ARIMA, Time Series Regression, Random Forest.*

KATA PENGANTAR

Puji syukur yang kehadirat Allah SWT, Tuhan Yang Maha Esa. Berkat rahmat dan ridho-Nya penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul **“Pemilihan Input dengan *Random Forest* pada Model *Time Series Regression* dan *Double Seasonal ARIMA* untuk Peramalan Data Pemakaian Beban Listrik Jangka Pendek”** dengan lancar.

Keberhasilan penyusunan Tugas Akhir ini tidak lepas dari banyaknya bantuan dan dukungan yang diberikan dari berbagai pihak. Oleh karena itu, pada kesempatan ini penulis mengucapkan terima kasih kepada:

1. Bapak Dr. Suhartono selaku Ketua Jurusan Statistika dan Bapak Dr. Sutikno, M.Si selaku Koordinator Program Studi S1 yang telah memberikan fasilitas untuk kelancaran penyelesaian Tugas Akhir.
2. Bapak Dr. Suhartono dan Bapak Dr. rer. pol. Dedy Dwi Prastyo, S.Si, M.Si selaku dosen pembimbing yang dengan sabar telah memberikan bimbingan, saran, dan dukungan selama penyusunan Tugas Akhir.
3. Ibu Santi Puteri Rahayu, S.Si, M.Si dan Bapak Dr. Sutikno, M.Si selaku dosen penguji yang telah memberikan banyak bantuan dan saran untuk kesempurnaan Tugas Akhir ini.
4. Bapak Dr. Agus Suharsono, M.S selaku dosen wali yang telah memberikan nasehat dan semangat.
5. Seluruh dosen Statistika ITS yang telah memberikan ilmu dan pengetahuan yang tak ternilai harganya, serta segenap karyawan Jurusan Statistika ITS.
6. Bapak Nur Hayadi dan rekan-rekan PT PLN (Persero) APB Jawa Timur yang telah memberikan ilmu dan pengalamannya kepada penulis.
7. Mama dan papa serta keluarga yang selalu memberikan dukungan, kasih sayang, semangat, dan doa yang tidak pernah putus kepada penulis.

8. Irfan Rhomdoni yang selalu sabar memberikan nasehat, semangat, dan dukungan kepada penulis.
9. Rosyida Inas, Rya Sofi Aulia, Hana Abshari, Dwi Handayani, Annisaa Lidia Wati, dan Sri Mulyani yang telah membantu serta selalu memberi semangat kepada penulis.
10. Rekan-rekan penerima Djarum Beasiswa Plus angkatan 31 yang telah mendukung dan memberi semangat kepada penulis.
11. Teman-teman Pejuang 115 atas semangat yang selalu diberikan kepada penulis.
12. Teman-teman Sigma 24 yang selalu memberikan dukungan kepada penulis selama ini.
13. Semua pihak yang telah memberikan bantuan hingga penyusunan laporan Tugas Akhir ini dapat terselesaikan.

Penulis berharap hasil Tugas Akhir ini dapat bermanfaat bagi kita semua. Semoga kebaikan dan bantuan yang telah diberikan kepada penulis dibalas dengan kebaikan yang lebih besar lagi oleh Tuhan Yang Maha Esa. Aamiin.

Surabaya, Desember 2016

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
COVER PAGE	iii
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xxi
DAFTAR LAMPIRAN	xxv
BAB I PENDAHULUAN	
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian.....	5
1.4 Manfaat Penelitian.....	5
1.5 Batasan Masalah.....	5
BAB II TINJAUAN PUSTAKA	
2.1 Beban Listrik.....	7
2.2 Statistika Deskriptif.....	8
2.3 Konsep Dasar <i>Time Series</i>	8
2.4 <i>Autoregressive Integrated Moving Average (ARIMA)</i> ...	9
2.4.1 Identifikasi Model	16
2.4.2 Estimasi dan Pengujian Parameter	18
2.4.3 Diagnosis Model	22
2.5 <i>Time Series Regression</i>	24
2.5.1 Estimasi Parameter (<i>Ordinary Least Square</i>)	25
2.5.2 Uji Signifikansi Parameter <i>Time Series</i> <i>Regression</i>	26
2.6 <i>Random Forest</i>	26
2.7 <i>Stepwise</i>	38

2.8	<i>Window Time</i>	39
2.9	Pemilihan Model Terbaik	40
BAB III METODOLOGI PENELITIAN		
3.1	Sumber Data dan Variabel Penelitian	41
3.2	Langkah Analisis	42
BAB IV ANALISIS DAN PEMBAHASAN		
4.1	Karakteristik Pemakaian Beban Listrik di Wilayah Jawa Timur	47
4.2	Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode <i>Time Series Regression</i> dan <i>Double Seasonal ARIMA</i>	56
4.2.1	Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode <i>Time Series Regression</i>	56
4.2.2	Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode <i>Double Seasonal ARIMA</i>	65
4.3	Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode <i>Time Series Regression</i> dan <i>Double Seasonal ARIMA</i> dengan Pemilihan Input Menggunakan <i>Random Forest</i>	78
4.3.1	Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode <i>Time Series Regression</i> dengan Pemilihan Input Menggunakan <i>Random Forest</i>	79
4.3.2	Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode <i>Double Seasonal ARIMA</i> dengan Pemilihan Input Menggunakan <i>Random Forest</i>	92
4.4	Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode <i>Time Series Regression</i> dan <i>Double Seasonal ARIMA</i> dengan Pemilihan Input Menggunakan Metode <i>Stepwise</i>	98
4.4.1	Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode <i>Time Series</i>	

	<i>Regression</i> dengan Pemilihan Input Menggunakan Metode <i>Stepwise</i>	98
4.4.2	Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode <i>Double Seasonal ARIMA</i> dengan Pemilihan Input Menggunakan Metode <i>Stepwise</i>	105
4.5	Perbandingan Kebaikan Model	110
BAB V KESIMPULAN DAN SARAN		
5.1	Kesimpulan.....	121
5.2	Saran	123
DAFTAR PUSTAKA		125
LAMPIRAN		129
BIODATA PENULIS		301

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Plot ACF (a) dan PACF (b) Simulasi MA(1) dengan $\theta_1 = 0,4$	13
Gambar 2.2 Plot ACF (a) dan PACF (b) Simulasi MA(1) dengan $\theta_1 = 0,6$	14
Gambar 2.3 Plot ACF (a) dan PACF (b) Simulasi MA(1) dengan $\theta_1 = 0,8$	15
Gambar 2.4 <i>Regression Tree Sample 1</i>	33
Gambar 2.5 Plot <i>Mean VI</i> Hasil Seleksi Tahap 1 <i>Random Forest</i>	34
Gambar 2.6 Plot <i>errOOB</i> Hasil Seleksi Tahap 2 <i>Random Forest</i>	35
Gambar 2.7 Plot <i>errOOB</i> Hasil Seleksi Tahap 3 <i>Random Forest</i>	35
Gambar 2.8 <i>Fixed Size Window Time 2 Tahun</i>	40
Gambar 3.1 Diagram Alir Tahapan Penelitian	46
Gambar 4.1 <i>Time Series Plot</i> Pemakaian Beban Listrik pada 24 September 2015 hingga 30 September 2016	50
Gambar 4.2 Pemakaian Beban Listrik Per Hari pada (a) Hari Biasa , (b) Hari Libur Nasional, dan (c) Selisih antara Hari Biasa dengan Hari Libur	52
Gambar 4.3 Pemakaian Beban Listrik Per Hari pada (a) Hari Biasa , (b) Bulan Puasa, dan (c) Selisih antara Hari Biasa dan Bulan Puasa	53
Gambar 4.4 Plot ACF Residual Model <i>Time Series Regression</i>	59
Gambar 4.5 Perbandingan Data Aktual dengan Peramalan Model <i>Time Series Regression</i>	60

Gambar 4.6	Perbandingan Data Aktual dengan Peramalan Model <i>Time Series Regression</i> pada Bulan Puasa dan Lebaran	60
Gambar 4.7	Perbandingan Data Aktual dan Peramalan Model <i>Time Series Regression</i> dengan Variasi Kalender	61
Gambar 4.8	Perbandingan Data Aktual dan Peramalan Model <i>Time Series Regression</i> dengan Variasi Kalender pada Data <i>In-Sample</i>	62
Gambar 4.9	Perbandingan Data Aktual dan Peramalan Model <i>Time Series Regression</i> dengan Variasi Kalender dan Hari Libur Nasional	63
Gambar 4.10	Perbandingan Data Aktual dan Peramalan Model <i>Time Series Regression</i> dengan Variasi Kalender dan Hari Libur Nasional pada Data <i>In-Sample</i>	64
Gambar 4.11	Perbandingan Data Aktual dan Peramalan Model <i>Time Series Regression</i> Data 1 Bulan	65
Gambar 4.12	<i>Time Series</i> Plot Pemakaian Beban Listrik Tanggal 24 September 2015 - 23 September 2016	66
Gambar 4.13	<i>Box-plot</i> Pemakaian Beban Listrik Tanggal 24 September 2015 - 23 September 2016.....	66
Gambar 4.14	ACF Plot Pemakaian Beban Listrik Tanggal 24 September 2015 - 23 September 2016.....	67
Gambar 4.15	PACF Plot Pemakaian Beban Listrik Tanggal 24 September 2015 - 23 September 2016.....	67
Gambar 4.16	ACF Plot Data <i>Differencing</i> lag 1, 48, dan 336	68
Gambar 4.17	PACF Plot Data <i>Differencing</i> lag 1, 48, dan 336	68
Gambar 4.18	Plot Box-Cox Data <i>Differencing</i> lag 1, 48, dan 336	69

Gambar 4.19	ACF Residual Model 2 <i>Double Seasonal</i> ARIMA	72
Gambar 4.20	Box- Plot Data <i>Differencing</i> lag 1, 48, dan 336	72
Gambar 4.21	Perbandingan Data Aktual dengan Peramalan Model <i>Double Seasonal</i> ARIMA	73
Gambar 4.22	ACF Data 1 Bulan yang di <i>Differencing</i> pada Lag 1, 48, dan 336	74
Gambar 4.23	PACF Data 1 Bulan yang di <i>Differencing</i> pada Lag 1, 48, dan 336.....	74
Gambar 4.24	ACF Residual Model <i>Double Seasonal</i> ARIMA Data 1 Bulan.....	76
Gambar 4.25	Uji Kolmogorov-Smirnov Residual Model <i>Double Seasonal</i> ARIMA Data 1 Bulan.....	77
Gambar 4.26	Perbandingan Data Aktual dengan Peramalan Model <i>Double Seasonal</i> ARIMA Data 1 Bulan.....	77
Gambar 4.27	Simulasi <i>Window Time</i>	79
Gambar 4.28	Perbandingan Data Aktual dengan Peramalan Model <i>Time Series Regression</i> Menggunakan <i>Random Forest</i> Tahap 3.....	81
Gambar 4.29	Perbandingan Data Aktual dengan Peramalan Model <i>Time Series Regression</i> Menggunakan <i>Random Forest</i> Tahap 2.....	89
Gambar 4.30	Perbandingan Data Aktual dengan Peramalan Model <i>Time Series Regression</i> Menggunakan 59 Variabel	91
Gambar 4.31	Perbandingan Data Aktual dengan Peramalan Model <i>Double Seasonal</i> ARIMA dengan <i>Random Forest</i>	97
Gambar 4.32	Perbandingan Data Aktual dengan Peramalan Model <i>Time Series Regression</i> Menggunakan Metode <i>Stepwise</i>	103

Gambar 4.33	Perbandingan Data Aktual dengan Peramalan Model <i>Time Series Regression</i> yang Menyertakan Lag Y_t Menggunakan Metode <i>Stepwise</i>	105
Gambar 4.34	Perbandingan Data Aktual dengan Peramalan Model <i>Double Seasonal ARIMA</i> dengan <i>Stepwise</i>	110
Gambar 4.35	Perbandingan Data Aktual dengan Peramalan Model <i>Time Series Regression</i> (a) Data 1 Tahun, (b) Penambahan Variasi Kalender, (c) Variasi Kalender dan Hari Libur, (d) Data 1 Bulan (e) Seleksi <i>Random Forest</i> Tahap 3, (f) Seleksi <i>Random Forest</i> Tahap 2, (g) Seleksi <i>Random Forest</i> Tahap 2 dengan 59 Variabel, (h) Seleksi <i>Stepwise</i> , (i) <i>Stepwise</i> dengan Lag Y_t	112
Gambar 4.36	Perbandingan Data Aktual dengan Peramalan Model <i>Double Seasonal ARIMA</i> (a) Data 1 Tahun, (b) Data 1 Bulan, (c) Seleksi <i>Random Forest</i> , dan (d) Seleksi <i>Stepwise</i>	116
Gambar 4.37	Plot RMSE dan MAPE Aditif (a) Model <i>Time Series Regression</i> dengan <i>Stepwise</i> dan (b) <i>Double Seasonal ARIMA</i> dengan <i>Random Forest</i>	119

DAFTAR TABEL

	Halaman
Tabel 2.1 Lag AR (p) Secara Teoritis dan Empirik Berdasarkan Simulasi Model MA (1).....	16
Tabel 2.2 Transformasi Box-Cox	17
Tabel 2.3 Karakteristik ACF dan PACF untuk model ARIMA	18
Tabel 2.4 Data <i>Sample</i> Pertama <i>The Hald Data</i>	30
Tabel 2.5 Data <i>Sample</i> X_1 yang Telah Diurutkan	30
Tabel 2.6 Hasil Fungsi Penyekat pada Variabel X_1	32
Tabel 3.1 Variabel pada Model <i>Time Series Regression</i>	41
Tabel 3.2 Variabel pada Model <i>Double Seasonal</i> ARIMA	42
Tabel 4.1 Rata-rata dan Standar Deviasi Konsumsi Listrik Per Setengah Jam	48
Tabel 4.2 Rata-rata dan Standar Deviasi Konsumsi Listrik Per Hari	49
Tabel 4.3 Pengujian Serentak Model 1 <i>Time Series Regresion</i>	58
Tabel 4.4 Daftar Hari Libur Nasional Mulai 24 September 2015 Hingga 23 September 2016.....	63
Tabel 4.5 Estimasi dan Pengujian Signifikansi Parameter Dugaan Model <i>Double Seasonal</i> ARIMA	69
Tabel 4.6 Uji Asumsi Residual <i>White Noise</i> pada Dugaan Model <i>Double Seasonal</i> ARIMA.....	71
Tabel 4.7 Uji Asumsi Residual Distribusi Normal pada Dugaan Model <i>Double Seasonal</i> ARIMA	71
Tabel 4.8 Nilai RMSE pada Dugaan Model <i>Double Seasonal</i> ARIMA.....	73

Tabel 4.9	Estimasi dan Pengujian Signifikansi Parameter Dugaan Model <i>Double Seasonal</i> ARIMA Data 1 Bulan.....	75
Tabel 4.10	Uji Asumsi Residual <i>White Noise</i> pada Dugaan Model <i>Double Seasonal</i> ARIMA Data 1 Bulan.....	76
Tabel 4.11	Hasil Pemilihan <i>Dummy</i> Tahap Ketiga dengan <i>Random Forest</i>	80
Tabel 4.12	Model <i>Time Series Regresion</i> dengan <i>Random Forest</i> pada Setiap <i>Window</i>	80
Tabel 4.13	<i>Dummy</i> Terpilih pada Tahap Kedua dengan <i>Random Forest</i>	82
Tabel 4.14	Hasil Pemilihan Lag pada <i>Window</i> 1 – 7 dengan <i>Random Forest</i>	92
Tabel 4.15	Model <i>Double Seasonal</i> ARIMA dengan Pemilihan Input Menggunakan <i>Random Forest</i>	94
Tabel 4.16	Uji Asumsi Residual <i>White Noise</i> pada Dugaan Model <i>Double Seasonal</i> ARIMA dengan <i>Random Forest</i>	95
Tabel 4.17	Uji Asumsi Residual Distribusi Normal pada Dugaan Model <i>Double Seasonal</i> ARIMA dengan <i>Random Forest</i>	97
Tabel 4.18	<i>Dummy</i> Terpilih pada Model <i>Time Series Regression</i> dengan Metode <i>Stepwise</i>	98
Tabel 4.19	Uji Asumsi Residual Distribusi Normal Dugaan Model <i>Time Series Regression</i> dengan <i>Stepwise</i> .	102
Tabel 4.20	Uji Asumsi Residual Distribusi Normal Dugaan Model <i>Time Series Regression</i> yang Menyertakan Lag Y_t dengan <i>Stepwise</i>	104
Tabel 4.21	Hasil Pemilihan Lag pada <i>Window</i> 1 – 7 dengan <i>Stepwise</i>	105

Tabel 4.22	Model <i>Double Seasonal</i> ARIMA dengan Pemilihan Input Menggunakan Metode <i>Stepwise</i>	106
Tabel 4.23	Uji Asumsi Residual <i>White Noise</i> pada Dugaan Model <i>Double Seasonal</i> ARIMA dengan <i>Stepwise</i>	108
Tabel 4.24	Uji Asumsi Residual Distribusi Normal pada Dugaan Model <i>Double Seasonal</i> ARIMA dengan <i>Stepwise</i>	109
Tabel 4.25	Perbandingan Nilai RMSE.....	111

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Hasil Pengujian Parsial Model <i>Time Series Regression</i>	129
Lampiran 2 Hasil Uji Kolmogorov-Smirnov Residual Model <i>Time Series Regression</i>	134
Lampiran 3 <i>Output Time Series Regression</i> dengan Variasi Kalender	135
Lampiran 4 <i>Normality Test</i> dan <i>ACF Residual Model Time Series Regression</i> dengan Variasi Kalender	140
Lampiran 5 <i>Output Time Series Regression</i> dengan Variasi Kalender dan Hari Libur Nasional....	141
Lampiran 6 <i>Normality Test</i> dan <i>ACF Residual Model Time Series Regression</i> dengan Variasi Kalender dan Hari Libur Nasional	147
Lampiran 7 <i>Output Time Series Regression</i> Data 1 Bulan	147
Lampiran 8 <i>Normality Test</i> dan <i>ACF Residual Model Time Series Regression</i> Data 1 Bulan.....	152
Lampiran 9 Output Pengujian Dickey Fuller Data yang Telah dilakukan <i>Differencing</i> lag 1, 48, dan 336 pada Pemodelan <i>Double Seasonal ARIMA</i>	152
Lampiran 10 <i>Syntax Double Seasonal ARIMA Model 1</i> atau $ARIMA(0,1,1)(0,1,1)^{48}(0,1,1)^{336}$	153
Lampiran 11 <i>Output Double Seasonal ARIMA Model 1</i> atau $ARIMA(0,1,1)(0,1,1)^{48}(0,1,1)^{336}$	154

Lampiran 12	<i>Syntax Double Seasonal ARIMA Model 2</i> atau ARIMA ([1,2,4,5,7,10,16,18,20,21, 27,30,41,43], 1,1)([47],1,1) ⁴⁸ (0,1,1) ³³⁶	155
Lampiran 13	<i>Output Double Seasonal ARIMA Model 2</i> atau ARIMA ([1,2,4,5,7,10,16,18,20, 21, 27,30,41,43], 1,1)([47],1,1) ⁴⁸ (0,1,1) ³³⁶	156
Lampiran 14	<i>Syntax Double Seasonal ARIMA Data 1</i> Bulan ARIMA ([5,6,11,20,24,30,42],1,1) (0,1,1) ⁴⁸ (0,1,1) ³³⁶	157
Lampiran 15	<i>Output Double Seasonal ARIMA Data 1</i> Bulan atau ARIMA ([5,6,11,20,24,30,42], 1,1)(0,1,1) ⁴⁸ (0,1,1) ³³⁶	158
Lampiran 16	<i>Output Random Forest Window 1 Model</i> <i>Time Series Regression</i>	159
Lampiran 17	<i>Output Random Forest Window 2 Model</i> <i>Time Series Regression</i>	160
Lampiran 18	<i>Output Random Forest Window 3 Model</i> <i>Time Series Regression</i>	161
Lampiran 19	<i>Output Random Forest Window 4 Model</i> <i>Time Series Regression</i>	162
Lampiran 20	<i>Output Random Forest Window 5 Model</i> <i>Time Series Regression</i>	163
Lampiran 21	<i>Output Random Forest Window 6 Model</i> <i>Time Series Regression</i>	164
Lampiran 22	<i>Output Random Forest Window 7 Model</i> <i>Time Series Regression</i>	165
Lampiran 23	<i>Output Plot Ranking Variabel dengan</i> <i>Random Forest pada Model Time Time</i> <i>Series Regression Window 1-7</i>	166

Lampiran 24	<i>Output Time Series Regression Window 1 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.....</i>	169
Lampiran 25	<i>Output Time Series Regression Window 2 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.</i>	169
Lampiran 26	<i>Output Time Series Regression Window 3 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.....</i>	170
Lampiran 27	<i>Output Time Series Regression Window 4 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.....</i>	170
Lampiran 28	<i>Output Time Series Regression Window 5 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.....</i>	171
Lampiran 29	<i>Output Time Series Regression Window 6 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.....</i>	171
Lampiran 30	<i>Output Time Series Regression Window 7 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.....</i>	172
Lampiran 31	<i>Normality Test dan ACF Residual Window 1-7 Model Time Series Regression dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.....</i>	172
Lampiran 32	<i>Output Time Series Regression Window 1 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest.....</i>	175

Lampiran 33	<i>Output Time Series Regression Window 2</i> dengan Variabel Preditor Hasil Seleksi Tahap 2 <i>Random Forest</i>	177
Lampiran 34	<i>Output Time Series Regression Window 3</i> dengan Variabel Preditor Hasil Seleksi Tahap 2 <i>Random Forest</i>	179
Lampiran 35	<i>Output Time Series Regression Window 4</i> dengan Variabel Preditor Hasil Seleksi Tahap 2 <i>Random Forest</i>	181
Lampiran 36	<i>Output Time Series Regression Window 5</i> dengan Variabel Preditor Hasil Seleksi Tahap 2 <i>Random Forest</i>	183
Lampiran 37	<i>Output Time Series Regression Window 6</i> dengan Variabel Preditor Hasil Seleksi Tahap 2 <i>Random Forest</i>	185
Lampiran 38	<i>Output Time Series Regression Window 7</i> dengan Variabel Preditor Hasil Seleksi Tahap 2 <i>Random Forest</i>	187
Lampiran 39	Normality Test dan ACF Residual <i>Window 1-7 Model Time Series</i> <i>Regression</i> dengan 59 Variabel Preditor	189
Lampiran 40	Variabel Terpilih Di Setiap <i>Window</i> pada <i>Model Time Series Regression</i> Hasil Seleksi Tahap 2 <i>Random Forest</i>	192
Lampiran 41	<i>Output Time Series Regression Window 1</i> dengan 59 Variabel Preditor.....	194
Lampiran 42	<i>Output Time Series Regression Window 2</i> dengan 59 Variabel Preditor.....	200
Lampiran 43	<i>Output Time Series Regression Window 3</i> dengan 59 Variabel Preditor.....	202

Lampiran 44	<i>Output Time Series Regression Window 4 dengan 59 Variabel Preditor.....</i>	204
Lampiran 45	<i>Output Time Series Regression Window 5 dengan 59 Variabel Preditor.....</i>	206
Lampiran 46	<i>Output Time Series Regression Window 6 dengan 59 Variabel Preditor.....</i>	208
Lampiran 47	<i>Output Time Series Regression Window 7 dengan 59 Variabel Preditor.....</i>	210
Lampiran 48	<i>Normality Test dan ACF Residual Window 1-7 Model Time Series Regression dengan 59 Variabel Preditor</i>	212
Lampiran 49	<i>Output Random Forest Window 1 Model Double Seasonal ARIMA.....</i>	215
Lampiran 50	<i>Output Random Forest Window 2 Model Double Seasonal ARIMA.....</i>	216
Lampiran 51	<i>Output Random Forest Window 3 Model Double Seasonal ARIMA.....</i>	217
Lampiran 52	<i>Output Random Forest Window 4 Model Double Seasonal ARIMA.....</i>	218
Lampiran 53	<i>Output Random Forest Window 5 Model Double Seasonal ARIMA.....</i>	219
Lampiran 54	<i>Output Random Forest Window 6 Model Double Seasonal ARIMA.....</i>	220
Lampiran 55	<i>Output Random Forest Window 7 Model Double Seasonal ARIMA.....</i>	221
Lampiran 56	<i>Output Plot Ranking Variabel dengan Random Forest pada Model Double Seasonal ARIMA Window 1-7</i>	222

Lampiran 57	<i>Syntax Double Seasonal ARIMA pada Window 1 dengan Seleksi Input Random Forest.....</i>	225
Lampiran 58	<i>Output Double Seasonal ARIMA pada Window 1 dengan Seleksi Input Random Forest.....</i>	226
Lampiran 59	<i>Syntax Double Seasonal ARIMA pada Window 2 dengan Seleksi Input Random Forest.....</i>	227
Lampiran 60	<i>Output Double Seasonal ARIMA pada Window 2 dengan Seleksi Input Random Forest.....</i>	228
Lampiran 61	<i>Syntax Double Seasonal ARIMA pada Window 3 dengan Seleksi Input Random Forest.....</i>	229
Lampiran 62	<i>Output Double Seasonal ARIMA pada Window 3 dengan Seleksi Input Random Forest.....</i>	230
Lampiran 63	<i>Syntax Double Seasonal ARIMA pada Window 4 dengan Seleksi Input Random Forest.....</i>	231
Lampiran 64	<i>Output Double Seasonal ARIMA pada Window 4 dengan Seleksi Input Random Forest.....</i>	232
Lampiran 65	<i>Syntax Double Seasonal ARIMA pada Window 5 dengan Seleksi Input Random Forest.....</i>	233
Lampiran 66	<i>Output Double Seasonal ARIMA pada Window 5 dengan Seleksi Input Random Forest.....</i>	234

Lampiran 67	<i>Syntax Double Seasonal ARIMA pada Window 6 dengan Seleksi Input Random Forest</i>	235
Lampiran 68	<i>Output Double Seasonal ARIMA pada Window 6 dengan Seleksi Input Random Forest</i>	236
Lampiran 69	<i>Syntax Double Seasonal ARIMA pada Window 7 dengan Seleksi Input Random Forest</i>	237
Lampiran 70	<i>Output Double Seasonal ARIMA pada Window 7 dengan Seleksi Input Random Forest</i>	238
Lampiran 71	<i>Output Time Series Regression Window 1 dengan Seleksi Input Menggunakan Metode Stepwise</i>	239
Lampiran 72	<i>Output Time Series Regression Window 2 dengan Seleksi Input Menggunakan Metode Stepwise</i>	242
Lampiran 73	<i>Output Time Series Regression Window 3 dengan Seleksi Input Menggunakan Metode Stepwise</i>	245
Lampiran 74	<i>Output Time Series Regression Window 4 dengan Seleksi Input Menggunakan Metode Stepwise</i>	248
Lampiran 75	<i>Output Time Series Regression Window 5 dengan Seleksi Input Menggunakan Metode Stepwise</i>	251
Lampiran 76	<i>Output Time Series Regression Window 6 dengan Seleksi Input Menggunakan Metode Stepwise</i>	253

Lampiran 77	<i>Output Time Series Regression Window 7 dengan Seleksi Input Menggunakan Metode Stepwise</i>	<i>257</i>
Lampiran 78	<i>Normality Test dan ACF Residual Window 1-7 Model Time Series Regression dengan Stepwise.....</i>	<i>260</i>
Lampiran 79	<i>Variabel Terpilih dari Seleksi Input Menggunakan Metode Stepwise pada Model Time Series Regression dengan Menambahkan Lag Y_t.....</i>	<i>262</i>
Lampiran 80	<i>Output Time Series Regression Window 1 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise</i>	<i>265</i>
Lampiran 81	<i>Output Time Series Regression Window 2 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise</i>	<i>267</i>
Lampiran 82	<i>Output Time Series Regression Window 3 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise</i>	<i>270</i>
Lampiran 83	<i>Output Time Series Regression Window 4 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise</i>	<i>272</i>
Lampiran 84	<i>Output Time Series Regression Window 5 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise</i>	<i>275</i>
Lampiran 85	<i>Output Time Series Regression Window 6 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise</i>	<i>277</i>

Lampiran 86	<i>Output Time Series Regression Window 7 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise</i>	280
Lampiran 87	<i>Normality Test dan ACF Residual Window 1-7 Model Time Series Regression yang Menyertakan Lag Y_t dengan Stepwise</i>	282
Lampiran 88	<i>Syntax Double Seasonal ARIMA pada Window 1 dengan Seleksi Input Stepwise</i>	285
Lampiran 89	<i>Output Double Seasonal ARIMA pada Window 1 dengan Seleksi Input Stepwise</i>	286
Lampiran 90	<i>Syntax Double Seasonal ARIMA pada Window 2 dengan Seleksi Input Stepwise</i>	287
Lampiran 91	<i>Output Double Seasonal ARIMA pada Window 2 dengan Seleksi Input Stepwise</i>	288
Lampiran 92	<i>Syntax Double Seasonal ARIMA pada Window 3 dengan Seleksi Input Stepwise</i>	289
Lampiran 93	<i>Output Double Seasonal ARIMA pada Window 3 dengan Seleksi Input Stepwise</i>	290
Lampiran 94	<i>Syntax Double Seasonal ARIMA pada Window 4 dengan Seleksi Input Stepwise</i>	291
Lampiran 95	<i>Output Double Seasonal ARIMA pada Window 4 dengan Seleksi Input Stepwise</i>	293
Lampiran 96	<i>Syntax Double Seasonal ARIMA pada Window 5 dengan Seleksi Input Stepwise</i>	293
Lampiran 97	<i>Output Double Seasonal ARIMA pada Window 5 dengan Seleksi Input Stepwise</i>	294
Lampiran 98	<i>Syntax Double Seasonal ARIMA pada Window 6 dengan Seleksi Input Stepwise</i>	295

Lampiran 99	<i>Output Double Seasonal ARIMA pada Window 6 dengan Seleksi Input Stepwise</i>	296
Lampiran 100	<i>Syntax Double Seasonal ARIMA pada Window 7 dengan Seleksi Input Stepwise</i>	297
Lampiran 101	<i>Output Double Seasonal ARIMA pada Window 7 dengan Seleksi Input Stepwise</i>	298
Lampiran 102	Surat Pernyataan Data Tugas Akhir.....	299

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Aktivitas manusia dalam menggunakan energi listrik mengalami peningkatan dari waktu ke waktu. Seperti dilansir oleh Kementerian Energi dan Sumber Daya Mineral (2015) yang menyatakan bahwa sepanjang tahun 2015 PT PLN (Persero) mencatat terjadi kenaikan beban listrik yang cukup signifikan, misalnya untuk wilayah Jakarta Raya dan Tangerang pada pertengahan tahun 2015 mencapai angka 7293 Mega Watt (MW) dari rata-rata pemakaian beban listrik stabil di kisaran 4000 MW hingga 6800 MW per bulan. Kenaikan beban listrik ini tidak terlepas dari tingginya konsumsi daya listrik dan peningkatan permintaan pasang baru oleh para pelanggan. Selain itu, kenaikan ini juga disebabkan karena semakin berkembangnya peradaban manusia di berbagai bidang, baik dari bidang ekonomi, sosial, budaya, maupun teknologi (Khair, 2011).

Peningkatan permintaan energi listrik yang tinggi harus diimbangi dengan ketersediaan pasokan listrik yang memadai. Ketersediaan energi listrik saat dibutuhkan menyebabkan tidak stabilnya daya listrik dari waktu ke waktu. Apabila suatu pembangkit listrik menghasilkan daya yang terlalu besar maka akan terjadi pemborosan energi yang mengakibatkan kerugian bagi perusahaan listrik. Sedangkan jika daya yang dihasilkan oleh pembangkit listrik lebih kecil dibanding permintaan maka mengakibatkan berkurangnya pasokan listrik hingga pemadaman listrik secara bergilir dan tentunya menyebabkan kerugian bagi konsumen (Triwulan, Hariyanto & Anwari, 2013). Oleh karena itu, perlu diperkirakan besarnya penggunaan beban listrik di masyarakat berdasarkan data sebelumnya sebagai acuan dalam rencana operasi sistem tenaga listrik. Perkiraan besarnya penggunaan beban listrik digunakan untuk mengoptimalkan penggunaan energi listrik di masyarakat agar tidak terjadi pemborosan maupun pemadaman listrik.

Terdapat beberapa metode yang dapat digunakan untuk meramalkan pemakaian beban listrik jangka pendek, diantaranya metode *Time Series Regression* dan *Double Seasonal ARIMA*. Metode *Time Series Regression* digunakan karena data pemakaian beban listrik diduga dipengaruhi oleh pola musiman dan *trend*, selain itu adanya bulan puasa dan hari raya idul fitri serta *special day* seperti hari libur nasional juga mempengaruhi pemakaian beban listrik yang cenderung menurun. Pola musiman pada data pemakaian beban listrik merupakan pola musiman ganda yang disebabkan oleh musiman harian dan musiman mingguan (Soares & Medeiros, 2008). Oleh karena itu metode *Double Seasonal ARIMA* juga digunakan dalam penelitian ini. Beberapa penelitian terkait dengan *Time Series Regression* yakni oleh Wulansari, Suryanto, Ferawati, Andalita & Suhartono (2014) yang meramalkan *netflow* uang kartal Bank Indonesia, kemudian oleh Suhartono, Lee & Prastyo (2015) menggunakan *Time Series Regression* untuk meramalkan penjualan retail celana jeans laki-laki dan perempuan. Bhaskaran, Gasparinni, Hajat, Smeeth & Armstrong (2013) juga mengaplikasikan *Time Series Regression* pada bidang epidemiologi lingkungan. Selanjutnya penelitian oleh Imai, Armstrong, Chalabi, Mangtani & Hashizume (2015) mengenai analisis ketergantungan penyakit menular terhadap cuaca menggunakan model *Time Series Regression*. Selain itu, Hajat, Chalabi, Wilkinson, Erens, Jones & Mays (2015) menganalisis mengenai kerentanan kesehatan masyarakat pada musim dingin di Inggris. Sedangkan penelitian mengenai *Double Seasonal ARIMA* telah dilakukan oleh Mohamed, Ahmad, Suhartono & Ismail (2011) yang meneliti tentang peramalan permintaan listrik di Malaysia. Kemudian oleh Sunaryo, Suhartono & Endharta (2011) yang meramalkan konsumsi listrik jangka pendek di Mengare, Gresik.

Salah satu masalah utama dalam model *Time Series Regression* yaitu memilih input atau prediktor yang sesuai untuk menghasilkan peramalan yang akurat. Sedangkan pada *Double Seasonal ARIMA*, salah satu permasalahan utamanya adalah pemilihan order atau lag yang sesuai untuk menghasilkan

peramalan yang akurat. Akhir-akhir ini, salah satu metode yang berkembang dan banyak diklaim dapat digunakan untuk memilih input atau prediktor yang optimal adalah *Random Forest* (Geneur, Poggi & Malot, 2015). *Random Forest* secara konsisten menghasilkan error yang lebih kecil dibandingkan dengan metode yang lain, selain itu *Random Forest* memiliki tingkat akurasi yang tinggi, relatif robust terhadap *outlier* dan *noise*, lebih cepat dari *boosting* dan *bagging*, serta metode ini sederhana untuk diaplikasikan (Breiman, 2001). Pada penelitian terdahulu lebih banyak dikembangkan metode *Random Forest* untuk kasus klasifikasi yang menghasilkan ketepatan klasifikasi lebih baik dibandingkan metode lain. Penelitian yang dilakukan diantaranya oleh Xie, Li, Ngai & Ying (2009) yang memprediksi kecenderungan pelanggan untuk berhenti melakukan bisnis dengan perusahaan dalam jangka waktu tertentu dengan menggunakan metode *Decision Trees*, *Artificial Neural Network*, *Class-Weighted Core Support Vector Machine* (CWC-SVM), dan *Random Forest*. Setelah dibandingkan hasilnya diperoleh kesimpulan bahwa metode *Random Forest* menghasilkan akurasi yang paling baik diantara metode yang lain. Selain itu, Zhang, Li & Fang (2009) melakukan penelitian tentang diskriminasi antara asam dan enzim alkalin berdasarkan komposisi struktur asam amino sekunder dengan metode *Random Forest*, *Support Vector Machine* (SVM), *Multilayer Perceotrons* (MLP), *Naive Bayes*, *k-NN*, *Decision Trees*, *Bayes Net*, *Boosted Ensemble*, dan *Bagged Ensemble*. Hasil penelitian menunjukkan bahwa akurasi *Random Forest* lebih besar dibandingkan seluruh metode lain yang digunakan. Selain kasus klasifikasi juga dikembangkan *Random Forest* untuk kasus regresi, seperti penelitian oleh Kocev, Dzeroski, White, Newell & Griffioen (2009) yang memprediksi kondisi vegetasi di seluruh negara bagian Victoria Australia menggunakan beberapa metode diantaranya *Random Forest*, *CART*, *Multi Target Regression Trees* (MTRT) dan *bagging*. Diperoleh kesimpulan bahwa akurasi tertinggi diperoleh dengan menggunakan metode *Random Forest*. Karena metode *Random Forest* dapat digunakan pada kasus regresi maka dalam penelitian ini akan diterapkan *Random Forest* pada

kasus *time series*. Berdasarkan hasil penelitian sebelumnya mengenai *Random Forest* pada kasus klasifikasi dan regresi tanpa proses seleksi variabel menunjukkan bahwa *Random Forest* menghasilkan akurasi yang lebih baik. Oleh karena itu, metode *Random Forest* yang digunakan sebagai *variable selection* diduga menghasilkan akurasi yang lebih baik dibandingkan metode lain.

Berdasarkan uraian di atas, pada penelitian ini akan dibahas mengenai aplikasi metode *Random Forest* untuk memilih input atau prediktor pada model *Time Series Regression* dan *Double Seasonal ARIMA* untuk meramalkan pemakaian beban listrik di wilayah Jawa Timur. Penelitian ini diharapkan mampu memberikan rekomendasi perkiraan beban listrik jangka pendek yang lebih akurat bagi PT PLN (Persero) khususnya wilayah Jawa Timur agar penggunaan energi listrik di masyarakat lebih optimal dan tidak terjadi pemborosan maupun pemadaman listrik.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, rumusan masalah pada penelitian ini berawal dari naik turunnya permintaan energi listrik di masyarakat sehingga PT PLN (Persero) harus mengimbangi dengan ketersediaan energi listrik yang memadai. Oleh karena itu, perlu dilakukan peramalan mengenai penggunaan beban listrik khususnya wilayah Jawa Timur agar energi listrik yang dibangkitkan oleh PT PLN (Persero) mencukupi kebutuhan listrik di Jawa Timur.

Secara khusus, permasalahan dalam penelitian ini yaitu :

1. Bagaimana model peramalan pemakaian beban listrik jangka pendek di wilayah Jawa Timur menggunakan metode *Time Series Regression* dan *Double Seasonal ARIMA* tanpa menggunakan *Random Forest*?
2. Bagaimana model peramalan pemakaian beban listrik jangka pendek di wilayah Jawa Timur menggunakan metode *Time Series Regression* dan *Double Seasonal ARIMA* dengan pemilihan input menggunakan *Random Forest*?

1.3 Tujuan Penelitian

Tujuan yang ingin dicapai pada penelitian ini yaitu sebagai berikut :

1. Mendapatkan model peramalan pemakaian beban listrik jangka pendek di wilayah Jawa Timur menggunakan metode *Time Series Regression* dan *Double Seasonal ARIMA* tanpa menggunakan *Random Forest*.
2. Mengaplikasikan metode *Random Forest* dalam pemilihan input pada model peramalan beban listrik jangka pendek di wilayah Jawa Timur menggunakan metode *Time Series Regression* dan *Double Seasonal ARIMA*.

1.4 Manfaat Penelitian

Hasil penelitian ini diharapkan mampu memberikan rekomendasi mengenai peramalan beban listrik jangka pendek yang lebih akurat bagi PT PLN (Persero) khususnya wilayah Jawa Timur untuk lebih mengoptimalkan penggunaan energi listrik di masyarakat agar tidak terjadi pemborosan maupun pemadaman listrik. Selain itu, bagi peneliti dapat mengaplikasikan ilmu statistika dalam kehidupan sehari-hari terutama dalam peramalan pemakaian beban listrik.

1.5 Batasan Masalah

Batasan masalah pada penelitian ini yaitu data sekunder mengenai pemakaian beban listrik di Jawa Timur menggunakan data per-setengah jam mulai tanggal 24 September 2015 hingga 30 September 2016. Karena dengan data selama 12 bulan diharapkan dapat memperoleh hasil peramalan yang lebih akurat. Selain itu, model yang terbentuk tidak memperhatikan asumsi *residual* tetapi menitikberatkan terhadap hasil peramalan yang lebih akurat.

BAB II

TINJAUAN PUSTAKA

Pada bab ini akan dijelaskan mengenai tinjauan pustaka yang digunakan baik tinjauan pustaka non statistik maupun tinjauan pustaka statistik. Berikut uraian terperinci mengenai tinjauan pustaka yang digunakan.

2.1 Beban Listrik

Sistem listrik merupakan sistem yang mengandung sumber tenaga listrik, dimana distribusi sumber tersebut terkoneksi menjadi satu dengan beban listrik (Mkhonza, 2013). Berdasarkan UU No. 30 Tahun 2009 tentang ketenagalistrikan, tenaga listrik adalah suatu bentuk energi sekunder yang dibangkitkan, ditransmisikan, dan didistribusikan untuk segala macam keperluan, tetapi tidak meliputi listrik yang dipakai untuk komunikasi, elektronika, atau isyarat. Sedangkan beban listrik memiliki beberapa pengertian diantaranya yaitu :

1. Suatu peralatan yang terkoneksi dengan sistem daya sehingga mampu mengkonsumsi energi listrik.
2. Total daya aktif dan/atau reaktif yang dikonsumsi oleh suatu peralatan yang terkoneksi ke sistem daya.
3. Daya keluaran suatu sistem pembangkit (*power plant*).
4. Bagian dari suatu sistem daya yang secara eksplisit tidak direpresentasikan model sistem, tetapi berlaku sebagai *single power-consuming device*.

Jenis beban listrik tergantung dari kegunaannya, seperti penerangan, stop kontak, mesin transportasi dalam bangunan (*elevator, escalator, lift*, maupun *travellator*), pompa distribusi air bersih dan pengolahan, pompa pemadam kebakaran, mesin-mesin *chiller* dan peralatan ventilasi mekanis, pompa mesin proses, pemanas listrik, serta peralatan lain seperti *kitchen equipment, laundry equipment, crane*, dan peralatan komunikasi. Berdasarkan jenis-jenis beban listrik tersebut dapat dihitung besaran tiap komponen yang nantinya digunakan untuk perhitungan total beban listrik (Nababan, 2008).

Penggunaan beban listrik di suatu daerah dapat diramalkan dengan menggunakan data masa lalu. Menurut jangka waktunya, peramalan beban listrik dibagi menjadi tiga periode yaitu sebagai berikut (Khair, 2011):

1. Peramalan Jangka Panjang (*Long-Term Forecasting*)
Merupakan peramalan yang memperkirakan keadaan dalam waktu beberapa tahun ke depan. Tujuannya adalah untuk mempersiapkan ketersediaan unit pembangkitan, sistem transmisi, serta distribusi.
2. Peramalan Jangka Menengah (*Mid-Term Forecasting*)
Merupakan peramalan dalam jangka waktu bulanan atau mingguan. Tujuannya untuk mempersiapkan jadwal persiapan dan operasional sisi pembangkit.
3. Peramalan Jangka Pendek (*Short-Term Forecasting*)
Merupakan peramalan dalam jangka waktu harian hingga setiap jam. Biasa digunakan untuk studi perbandingan beban listrik perkiraan dan aktual (*realtime*).

2.2 Statistika Deskriptif

Statistika deskriptif merupakan metode untuk mengorganisasi dan merangkum suatu informasi yang meliputi pembuatan grafik, diagram, dan tabel serta perhitungan seperti ukuran pemusatan dan penyebaran data. Ukuran pemusatan yang umum digunakan yaitu median, modus dan *mean*, sedangkan ukuran penyebaran meliputi *range*, *interquartile*, varians dan deviasi standar (Istalo, 2001).

Ukuran pemusatan data digunakan untuk melihat kecenderungan berkumpulnya data pada suatu nilai tertentu, sedangkan ukuran penyebaran data digunakan untuk membandingkan penyebaran dua distribusi data atau lebih. Pada penelitian ini untuk mengeksplorasi data pemakaian beban listrik menggunakan ukuran pemusatan dan penyebaran data yang meliputi *mean*, median, maksimum, minimum, dan varians. Selain itu juga dilakukan eksplorasi secara visual menggunakan plot dan *box-plot*.

2.3 Konsep Dasar *Time Series*

Wei (2006) menyatakan bahwa analisis *time series* dapat diartikan sebagai serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu kejadian dengan interval waktu yang tetap dimana setiap pengamatan dinyatakan sebagai variabel random Y_t . Secara umum, tujuan dari analisis *time series* adalah untuk menemukan bentuk pola dari data di masa lalu dan melakukan peramalan terhadap sifat-sifat dari data di masa yang akan datang. Pada saat $t_1, t_2, t_3, \dots, t_n$ pengamatan suatu deret berkala membentuk suatu deret dan mempunyai variabel random $Y_{t1}, Y_{t2}, Y_{t3}, \dots, Y_{tn}$ dengan fungsi distribusi bersama yaitu $F(Y_{t1}, Y_{t2}, Y_{t3}, \dots, Y_{tn})$.

Dalam analisis *time series*, data pengamatan yang disimbolkan dengan Y_t disyaratkan mengikuti proses stokastik yaitu suatu kelompok data berdasarkan waktu yang tersusun oleh variabel random $Y(\omega, t)$ dimana ω adalah ruang sampel dan t adalah indeks waktu (Wei, 2006). Contoh data *time series* yaitu data harian dari Indeks Harga Saham Gabungan (IHSG) di Bursa Efek Jakarta.

2.4 *Autoregressive Integrated Moving Average (ARIMA)*

ARIMA merupakan salah satu model yang sering digunakan dalam peramalan data *time series*. ARIMA forecasting terbagi menjadi empat yaitu *Autoregressive (AR)*, *Moving Average (MA)*, *Autoregressive Moving Average (ARMA)*, dan *Autoregressive Integrated Moving Average (ARIMA)*. Model *Autoregressive (AR)* merupakan suatu model yang menunjukkan adanya keterkaitan antara suatu nilai pada waktu sekarang (Y_t) dengan nilai pada waktu sebelumnya (Y_{t-k}), ditambah dengan suatu nilai acak a_t yang *white noise* dan berdistribusi normal $(0, \sigma_a^2)$. Model *Moving Average (MA)* menunjukkan adanya keterkaitan antara nilai pada waktu sekarang (Y_t) dengan nilai *residual* pada waktu sebelumnya (a_{t-k} dengan $k = 1, 2, 3, \dots$). Gabungan dari model *Autoregressive (AR)* dan *Moving Average (MA)* akan membentuk model *Autoregressive Moving Average (ARMA)*, sedangkan ARIMA

(p, d, q) merupakan model ARMA(p, q) yang memperoleh *differencing* sebanyak d . Bentuk umum dari model ARIMA(p, d, q) adalah :

$$\phi_p(B)(1-B)^d Y_t = \theta_q(B) a_t \quad (2.1)$$

dengan p adalah orde model AR, q adalah orde model MA, d adalah orde *differencing*, dan

$$\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$$

$$\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q).$$

Generalisasi dari model ARIMA untuk data yang memiliki pola musiman ditulis dengan ARIMA(p, d, q)(P, D, Q)^s dan dirumuskan sebagai berikut :

$$\phi_p(B) \Phi_P(B^s)(1-B)^d (1-B^s)^D Y_t = \theta_q(B) \Theta_Q(B^s) a_t \quad (2.2)$$

dengan s merupakan periode musiman, dan

$$\Phi_P(B^s) = (1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps})$$

$$\Theta_Q(B^s) = (1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs}).$$

Pada data konsumsi listrik jangka pendek, pola musiman ganda terdapat pada musiman harian dan musiman mingguan sehingga disebut dengan pola musiman ganda multiplikatif atau *Double Seasonal* ARIMA (Soares & Medeiros, 2008). Model *Double Seasonal* ARIMA ditulis dengan ARIMA(p, d, q)(P_1, D_1, Q_1)^{s₁} (P_2, D_2, Q_2)^{s₂} yang mempunyai bentuk umum sebagai berikut :

$$\begin{aligned} \phi_p(B) \Phi_{P_1}(B^{s_1}) \Phi_{P_2}(B^{s_2}) (1-B)^d (1-B^{s_1})^{D_1} (1-B^{s_2})^{D_2} Y_t \\ = \theta_q(B) \Theta_{Q_1}(B^{s_1}) \Theta_{Q_2}(B^{s_2}) a_t \end{aligned} \quad (2.3)$$

dengan s_1 dan s_2 adalah periode musiman yang berbeda. Pada penelitian ini model *Double Seasonal* ARIMA mengacu pada model AR(p) dengan menerapkan *causality* dalam model ARIMA dimana $q = Q_1 = Q_2 = 0$. Berikut merupakan simulasi model *Double Seasonal* ARIMA berdasarkan penelitian yang dilakukan oleh Sunaryo dkk. (2011) yang meramalkan beban listrik jangka pendek di Indonesia. Model *Double Seasonal* ARIMA terbaik yang

terbentuk yaitu ARIMA $([1,2,3,4,6,7,9,10,14,21,33],1,[8])(0,1,1)^{24}$
 $(1,1,0)^{168}$ dengan uraian sebagai berikut :

$$\begin{aligned} & (1+0,164B+0,139B^2+0,155B^3+0,088B^4+0,112B^6 \\ & +0,152B^7+0,077B^9+0,067B^{10}+0,069B^{14}+0,089B^{21} \\ & +0,072B^{33})(1+0,543B^{168})(1-B)(1-B^{24})(1-B^{168})Y_t = \\ & (1-0,0674B^8)(1-0,0803B^{24})a_t \end{aligned}$$

sehingga jika dijabarkan diperoleh hasil bahwa,


$$\begin{aligned} Y_t = & 0,836Y_{t-1} + 0,025Y_{t-2} - 0,016Y_{t-3} + 0,067Y_{t-4} + 0,088Y_{t-5} - 0,112Y_{t-6} \\ & - 0,04Y_{t-7} + 0,152Y_{t-8} - 0,077Y_{t-9} + 0,01Y_{t-10} + 0,067Y_{t-11} - 0,069Y_{t-14} \\ & + 0,069Y_{t-15} - 0,089Y_{t-21} + 0,089Y_{t-22} + Y_{t-24} + 1,164Y_{t-25} + 0,303Y_{t-26} \\ & + 0,294Y_{t-27} + 0,243Y_{t-28} + 0,088Y_{t-29} + 0,112Y_{t-30} + 0,264Y_{t-31} \\ & + 0,152Y_{t-32} + 0,005Y_{t-33} + 0,216Y_{t-34} + 0,067Y_{t-35} + 0,069Y_{t-38} \\ & + 0,069Y_{t-39} + 0,089Y_{t-45} + 0,089Y_{t-46} + 0,072Y_{t-57} + 0,072Y_{t-58} \\ & + 0,457Y_{t-168} - 0,382Y_{t-169} - 0,011Y_{t-170} + 0,007Y_{t-171} - 0,031Y_{t-172} \\ & - 0,04Y_{t-173} + 0,051Y_{t-174} + 0,018Y_{t-175} - 0,069Y_{t-176} + 0,035Y_{t-177} \\ & - 0,004Y_{t-178} - 0,031Y_{t-179} + 0,032Y_{t-182} - 0,032Y_{t-183} + 0,041Y_{t-189} \\ & - 0,041Y_{t-190} - 0,457Y_{t-192} + 1,468Y_{t-193} + 0,189Y_{t-194} + 0,143Y_{t-195} \\ & + 0,199Y_{t-196} + 0,136Y_{t-197} - 0,051Y_{t-198} + 0,104Y_{t-199} + 0,235Y_{t-200} \\ & - 0,002Y_{t-201} + 0,055Y_{t-202} + 0,103Y_{t-203} - 0,032Y_{t-206} + 0,106Y_{t-207} \\ & - 0,041Y_{t-213} + 0,137Y_{t-214} - 0,033Y_{t-225} + 0,111Y_{t-226} + 0,543Y_{t-336} \\ & - 0,454Y_{t-337} - 0,014Y_{t-338} + 0,009Y_{t-339} - 0,036Y_{t-340} - 0,048Y_{t-341} \\ & + 0,061Y_{t-342} + 0,022Y_{t-343} - 0,083Y_{t-344} + 0,042Y_{t-345} - 0,006Y_{t-346} \\ & - 0,036Y_{t-347} + 0,037Y_{t-350} - 0,037Y_{t-351} + 0,048Y_{t-357} - 0,048Y_{t-358} \\ & - 0,543Y_{t-360} + 0,454Y_{t-361} + 0,014Y_{t-362} - 0,009Y_{t-363} + 0,036Y_{t-364} \\ & + 0,048Y_{t-365} - 0,061Y_{t-366} - 0,022Y_{t-367} + 0,083Y_{t-368} - 0,003Y_{t-369} \\ & - 0,033Y_{t-370} + 0,036Y_{t-371} - 0,037Y_{t-374} + 0,037Y_{t-375} - 0,048Y_{t-381} \\ & + 0,048Y_{t-382} - 0,039Y_{t-393} + 0,039Y_{t-394} - 0,0674a_{t-8} - 0,0803a_{t-24} \\ & + 0,005a_{t-32} + a_t \end{aligned}$$

atau dapat ditulis sebagai berikut,


$$\begin{aligned}
 Y_t = & f(Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}, Y_{t-7}, Y_{t-8}, Y_{t-9}, Y_{t-10}, Y_{t-11}, \\
 & Y_{t-14}, Y_{t-15}, Y_{t-21}, Y_{t-22}, Y_{t-24}, Y_{t-25}, Y_{t-26}, Y_{t-27}, Y_{t-28}, Y_{t-29}, \\
 & Y_{t-30}, Y_{t-31}, Y_{t-32}, Y_{t-33}, Y_{t-34}, Y_{t-35}, Y_{t-38}, Y_{t-39}, Y_{t-45}, Y_{t-46}, \\
 & Y_{t-57}, Y_{t-58}, Y_{t-168}, Y_{t-169}, Y_{t-170}, Y_{t-171}, Y_{t-172}, Y_{t-173}, Y_{t-174}, \\
 & Y_{t-175}, Y_{t-176}, Y_{t-177}, Y_{t-178}, Y_{t-179}, Y_{t-182}, Y_{t-183}, Y_{t-189}, Y_{t-190}, \\
 & Y_{t-192}, Y_{t-193}, Y_{t-194}, Y_{t-195}, Y_{t-196}, Y_{t-197}, Y_{t-198}, Y_{t-199}, Y_{t-200}, \\
 & Y_{t-201}, Y_{t-202}, Y_{t-203}, Y_{t-206}, Y_{t-207}, Y_{t-213}, Y_{t-214}, Y_{t-225}, Y_{t-226}, \\
 & Y_{t-336}, Y_{t-337}, Y_{t-338}, Y_{t-339}, Y_{t-340}, Y_{t-341}, Y_{t-342}, Y_{t-343}, Y_{t-344}, \\
 & Y_{t-345}, Y_{t-346}, Y_{t-347}, Y_{t-350}, Y_{t-351}, Y_{t-357}, Y_{t-358}, Y_{t-360}, Y_{t-361}, \\
 & Y_{t-362}, Y_{t-363}, Y_{t-364}, Y_{t-365}, Y_{t-366}, Y_{t-367}, Y_{t-368}, Y_{t-369}, Y_{t-370}, \\
 & Y_{t-371}, Y_{t-374}, Y_{t-375}, Y_{t-381}, Y_{t-382}, Y_{t-393}, Y_{t-394}) \\
 & + f(a_{t-8}, a_{t-24}, a_{t-32}) + a_t.
 \end{aligned} \tag{2.4}$$

Dari uraian model ARIMA di atas, berdasarkan subset orde AR(p) diperoleh lag yang berpengaruh terhadap model berada pada *range* lag 1 sampai dengan lag 394. Sedangkan, berdasarkan orde MA(q) *residual* yang berpengaruh terhadap model yaitu a_{t-8} , a_{t-24} , dan a_{t-32} . Variabel prediktor yang banyak tersebut akan mempersulit pembentukan model serta memerlukan waktu yang lebih lama. Oleh karena itu, perlu dilakukan seleksi variabel untuk memperoleh variabel prediktor (lag) yang berpengaruh signifikan dalam model dengan menggunakan metode *Random Forest*. Namun, variabel prediktor yang dapat diseleksi menggunakan *Random Forest* hanya variabel berdasarkan orde AR(p) yaitu antara *range* lag 1 hingga 394. Orde MA(q) tidak dapat diseleksi karena melibatkan *residual* sehingga sulit untuk dilakukan proses seleksi variabel. Berdasarkan hal tersebut maka banyaknya variabel prediktor yang diseleksi menggunakan *Random Forest* sebanyak 394 lag. Lag-lag yang berada diantara lag 1 hingga lag 394 yang awalnya tidak terdapat dalam model di atas, kemudian diikutsertakan dalam proses seleksi variabel karena mengacu pada prinsip kausalitas dimana MA(q) yang dapat diubah menjadi AR



(∞). Misalkan terdapat suatu model MA(1), secara teori jika diubah menjadi model AR(p) maka MA(1) = AR(∞). Namun secara empirik, ∞ tersebut memiliki suatu nilai yang berhingga. Berdasarkan simulasi MA(1) dengan nilai parameter yang berbeda-beda yaitu $\theta_1 = 0,4$, $\theta_1 = 0,6$, dan $\theta_1 = 0,8$ diperoleh plot ACF dan PACF seperti yang disajikan pada Gambar 2.1, 2.2, dan 2.3 berikut.



Gambar 2.1 Plot ACF (a) dan PACF (b) Simulasi MA(1) dengan $\theta_1 = 0,4$.



Gambar 2.2 Plot ACF (a) dan PACF (b) Simulasi MA(1) dengan $\theta_1 = 0.6$.



Gambar 2.3 Plot ACF (a) dan PACF (b) Simulasi MA(1) dengan $\theta_1 = 0,8$.

Tabel 2.1 Lag AR(p) Secara Teoritis dan Empirik Berdasarkan Simulasi Model MA(1).

Model	θ_1	Lag AR(p)	
		Teoritis	Empirik
MA(1)	0,4	∞	2
MA(1)	0,6	∞	4
MA(1)	0,8	∞	8

Dari simulasi pada Gambar 2.1, 2.2, dan 2.3 diperoleh kesimpulan yang disajikan pada Tabel 2.1. Berdasarkan tabel tersebut maka untuk model MA(1) dengan $\theta_1 = 0,8$ sama dengan AR(8). Oleh karena itu, alasan mengapa lag-lag antara *range* lag 1 hingga 394 yang awalnya tidak terdapat dalam model kemudian diikutsertakan dalam proses seleksi *Random Forest* agar model MA(q) juga terlibat dalam proses seleksi tersebut. Sehingga berdasarkan persamaan (2.4) yang akan dilakukan proses seleksi variabel menggunakan *Random Forest* dapat ditulis menjadi persamaan berikut.

$$Y_t = f(Y_{t-1}, Y_{t-2}, Y_{t-3}, \dots, Y_{t-394}) + a_t.$$

Dalam melakukan pemodelan ARIMA terdapat beberapa langkah yang harus dilakukan, yaitu identifikasi model, estimasi dan pengujian parameter, diagnosis model, pemilihan model terbaik, dan peramalan (Wei, 2006).

2.4.1 Identifikasi Model

Proses identifikasi model dapat dilakukan melalui dua tahap yaitu dengan melihat kestasioneran data dalam varians dan *mean* melalui *time series plot*, selanjutnya dengan plot ACF dan plot PACF. Berikut uraian mengenai kedua tahap identifikasi model :

1. Kestasioneran Data

Kestasioneran data *time series* merupakan suatu keadaan yang berdasarkan pada nilai *mean* dan varians yang konstan. Terdapat dua jenis pengecekan kestasioneran data yaitu stasioner dalam *mean* dan stasioner dalam varians. Jika plot-plot *time series* menyebar disekitar garis sejajar dengan sumbu waktu (t) maka data dikatakan stasioner dalam *mean*. Apabila

data tidak stasioner dalam *mean*, maka dapat diatasi dengan cara melakukan *differencing* dengan rumus berikut :

$$Y_t = Y_t - Y_{t-1} \quad (2.5)$$

dengan Y_t merupakan pengamatan pada waktu ke- t dan Y_{t-1} merupakan pengamatan pada waktu $t-1$. Sedangkan, suatu data dikatakan stasioner dalam varians jika plot *time series* yang terbentuk tidak memperlihatkan adanya perubahan varians yang jelas dari waktu ke waktu. Jika data tidak stasioner dalam varians maka transformasi Box-Cox dengan rumus sebagai berikut :

$$T(Y_t) = Y_t^{(\lambda)} = \frac{Y_t^\lambda - 1}{\lambda}, \lambda \neq 0 \quad (2.6)$$

$$\lim_{\lambda \rightarrow 0} T(Y_t) = \lim_{\lambda \rightarrow 0} \frac{Y_t^\lambda - 1}{\lambda} = \ln(Y_t), \lambda = 0 \quad (2.7)$$

Transformasi Box-Cox berbeda-beda tergantung pada nilai lambda (λ) yang dimiliki, macam-macam bentuk transformasi Box-Cox disajikan dalam tabel berikut (Wei, 2006):

Tabel 2.2 Transformasi Box-Cox

Nilai lambda (λ)	Transformasi
-1,0	$\frac{1}{Y_t}$
-0,5	$\frac{1}{\sqrt{Y_t}}$
0,0	$\ln Y_t$
0,5	$\sqrt{Y_t}$
1,0	Y_t (Tidak ditransformasi)

2. Plot ACF dan Pot PACF

Plot ACF digunakan untuk menduga model yang sesuai pada suatu proses yang stasioner dalam mean ($E(Y_t) = \mu$) maupun dalam varians. Selain dengan plot ACF, pendugaan model juga dapat dilakukan secara bersama-sama dengan plot PACF (*Partial Autocorrelation Function*). Berikut merupakan ciri-ciri dugaan model ARIMA berdasarkan lag yang keluar pada plot ACF dan PACF (Wei, 2006).

Tabel 2.3 Karakteristik ACF dan PACF untuk model ARIMA.

Model	ACF	PACF
AR(p)	Turun cepat membentuk eksponensial	Terpotong setelah lag p
MA(q)	Terpotong setelah lag q	Turun cepat membentuk eksponensial
ARMA(p, q)	Terpotong setelah lag $q - p$	Terpotong setelah lag $p - q$

2.4.2 Estimasi dan Pengujian Parameter

Salah satu metode yang dapat digunakan untuk mengestimasi parameter model ARIMA adalah metode *least square (conditional least square)*. Metode ini bekerja dengan meminimumkan jumlah kuadrat error (SSE) dalam model (Cryer dan Chan, 2008). Misalkan model AR(p) :

$$Y_t - \mu = \phi_1(Y_{t-1} - \mu) + \phi_2(Y_{t-2} - \mu) + \dots + \phi_p(Y_{t-p} - \mu) + a_t. \quad (2.8)$$

Model AR (p) tpada persamaan (2.8) dapat diibaratkan sebagai model regresi dengan variabel prediktor yaitu $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ dan variabel respon adalah Y_t . Metode *least square estimation* meminimumkna jumlah kuadrat eror dari differensiasi :

$$(Y_t - \mu) - \phi_1(Y_{t-1} - \mu) - \phi_2(Y_{t-2} - \mu) - \dots - \phi_p(Y_{t-p} - \mu). \quad (2.9)$$

Berdasarkan persamaan tersebut, jika terdapat pengamatan Y_1, Y_2, \dots, Y_n maka proses penjumlahan dapat dilakukan

menggunakan $t = p+1, p+2, \dots, n$ sehingga metode estimasi *least square* meminimumkan persamaan berikut.

$$S_c(\phi_1, \phi_2, \dots, \phi_p, \mu) = \sum_{t=p+1}^n \left[(Y_t - \mu) - \phi_1(Y_{t-1} - \mu) - \dots - \phi_p(Y_{t-p} - \mu) \right]^2. \quad (2.10)$$

Persamaan (2.10) disebut juga fungsi *conditional sum of squares*. Berdasarkan prinsip dari *least squares*, parameter ϕ dan μ diestimasi menggunakan masing-masing nilai yang meminimumkan $S(\phi, \mu)$. Proses penurunan $\frac{\partial S_c}{\partial \mu} = 0$ ditampilkan pada persamaan (2.11).

$$\sum_{t=p+1}^n 2 \left[(Y_t - \mu) - \phi_1(Y_{t-1} - \mu) - \dots - \phi_p(Y_{t-p} - \mu) \right] \left(-1 + \phi_1 + \dots + \phi_p \right) = 0. \quad (2.11)$$

Hasil penurunan yang ditunjukkan oleh persamaan (2.11) memberikan nilai estimasi parameter μ dari model AR (p) sedemikian hingga nilai estimasi yang diperoleh ditunjukkan pada persamaan (2.12) berikut.

$$\mu = \frac{1}{(n-p)(1-\phi_1-\dots-\phi_p)} \left[\sum_{t=p+1}^n Y_t - \phi_1 \sum_{t=p+1}^n Y_{t-1} - \dots - \phi_p \sum_{t=p+1}^n Y_{t-p} \right]. \quad (2.12)$$

Untuk n berukuran besar diketahui bahwa:

$$\frac{1}{n-p} \sum_{t=p+1}^n Y_t \approx \frac{1}{n-p} Y_{t-1} \approx \dots \approx \frac{1}{n-p} Y_{t-p} \approx \bar{Y}. \quad (2.13)$$

Berdasarkan persamaan (2.13) dapat diketahui bahwa nilai mendekati \bar{Y} sehingga persamaan (2.12) dapat disederhanakan menjadi sebagai berikut.

$$\hat{\mu} \approx \frac{1}{(1 - \phi_1 - \phi_2 - \dots - \phi_p)} (\bar{Y} - \phi_1 \bar{Y} - \phi_2 \bar{Y} - \dots - \phi_p \bar{Y}) = \bar{Y}. \quad (2.14)$$

Selanjutnya, *least square* meminimumkan $S_c(\phi_1, \phi_2, \dots, \phi_p)$ untuk mendapatkan estimasi parameter dari ϕ_i . Adapun estimasi parameter ϕ_1 didapatkan dari $\frac{\partial S_c}{\partial \phi_1} = 0$ yang ditunjukkan oleh persamaan berikut.

$$\frac{\partial S_c}{\partial \phi_1} = 2 \sum_{t=p+1}^n \left[(Y_t - \bar{Y}) - \phi_1 (Y_{t-1} - \bar{Y}) - \dots - \phi_p (Y_{t-p} - \bar{Y}) \right] (Y_{t-1} - \bar{Y}). \quad (2.15)$$

Persamaan (2.15) dapat dituliskan kembali menjadi sebagai berikut.

$$\begin{aligned} \sum_{t=p+1}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y}) &= \left[\sum_{t=p+1}^n (Y_{t-1} - \bar{Y})^2 \right] \phi_1 \\ &+ \left[\sum_{t=p+1}^n (Y_{t-1} - \bar{Y})(Y_{t-2} - \bar{Y}) \right] \phi_2 \\ &+ \dots + \left[\sum_{t=p+1}^n (Y_{t-1} - \bar{Y})(Y_{t-p} - \bar{Y}) \right] \phi_p. \end{aligned} \quad (2.16)$$

Penjumlahan dari hasil lag $\sum_{t=p+1}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})$ mendekati nilai dari pembilang r_1 , namun tidak terdapat suatu hasil $(Y_p - \bar{Y})(Y_{p-1} - \bar{Y})$.

Kondisi yang sama terdapat pada $\sum_{t=p+1}^n (Y_{t-1} - \bar{Y})(Y_{t-p} - \bar{Y})$ yang tidak

menyertakan suatu hasil $(Y_n - \bar{Y})(Y_{n-1} - \bar{Y})$. Apabila kedua ruas pada persamaan (2.16) dibagi dengan $\sum_{t=p+1}^n (Y_t - \bar{Y})^2$, maka hasil yang diperoleh adalah sebagai berikut.

$$r_1 = \phi_1 + r_1\phi_2 + r_2\phi_3 + \dots + r_{p-1}\phi_p. \quad (2.17)$$

Estimasi untuk parameter $\phi_2, \phi_3, \dots, \phi_p$ dapat dilakukan dengan cara yang sama sedemikian hingga hasil estimasinya dengan menyelesaikan persamaan berikut.

$$\left. \begin{aligned} \phi_1 + r_1\phi_2 + r_2\phi_3 + \dots + r_{p-1}\phi_p &= r_1 \\ r_1\phi_1 + \phi_2 + r_1\phi_3 + \dots + r_{p-2}\phi_p &= r_2 \\ &\vdots \\ r_{p-1}\phi_1 + r_{p-2}\phi_2 + r_{p-3}\phi_3 + \dots + \phi_p &= r_p \end{aligned} \right\} \quad (2.18)$$

Persamaan (2.18) disebut juga persamaan Yule-Walker untuk model AR (p). Berdasarkan persamaan Yule-Walker r_k merupakan pengganti dari ρ_k , $k = 1, 2, \dots, p$ dengan ρ_k merupakan autokorelasi lag ke- k (Cryer dan Chan, 2008).

Parameter yang telah diperoleh selanjutnya dilakukan pengujian signifikansinya. Misalkan secara umum parameter model ARIMA dinotasikan dengan β maka signifikansi parameter β diuji dengan hipotesis berikut :

$$H_0 : \beta = 0$$

$$H_1 : \beta \neq 0$$

Statistik uji yang digunakan adalah :

$$t_{hitung} = \frac{\hat{\beta}}{SE(\hat{\beta})}. \quad (2.19)$$

Tingkat signifikansi pengujian sebesar α dan J menyatakan banyaknya parameter dalam model, H_0 ditolak bila :

$$|t_{hitung}| > t_{\frac{\alpha}{2}, n-J}$$

yang berarti parameter model adalah signifikan atau berbeda dengan nol (Wei, 2006).

2.4.3 Diagnosis Model

Pengujian kesesuaian model dilakukan dengan menguji *residual* dari model yang terbentuk. Model dikatakan sesuai jika pengujian *residual* yang didapatkan memenuhi asumsi *white noise* dan berdistribusi normal. Uji asumsi *white noise* meliputi pengujian identik (homogen) dan independen. Pengujian identik (homogen) dari varians *residual* menggunakan uji deteksi ARCH/GARCH melalui pengujian *Lagrange Multiplier* (LM). Sedangkan pengujian independen menggunakan uji Ljung-Box-Pierce Ljung-Box-Pierce. Pengujian normalitas data menggunakan uji Kolmogorov-Smirnov.

Uji *Lagrange Multiplier* bertujuan untuk mendeteksi adanya kasus heteroskedastisitas. Misal diberikan suatu model *time series* berikut.

$$y_t = \mu_t + \varepsilon_t$$

dimana μ_t adalah *conditional mean* dalam suatu proses dan ε_t merupakan *residual* dengan *mean* nol. Misalkan *residual* dibentuk menjadi persamaan berikut.

$$\varepsilon_t = \sigma_t z_t$$

dengan z_t merupakan suatu proses yang *white noise*. Maka σ_t^2 dimodelkan menjadi :

$$\sigma_t^2 = a_0 + a_1 \varepsilon_{t-1}^2 + \dots + a_q \varepsilon_{t-q}^2 = a_0 + \sum_{i=1}^q a_i \varepsilon_{t-i}^2$$

dimana $a_0 > 0$ dan $a_i \geq 0$, $i > 0$. Sehingga hipotesis yang digunakan dalam pengujian *Lagrange Multiplier* yaitu sebagai berikut.

$$H_0 : a_1 = a_2 = \dots = a_k = 0$$

$$H_1 : \text{minimal ada satu } a_i \neq 0, \text{ untuk } i = 1, 2, \dots, k$$

Statistik uji yang digunakan yaitu :

$$LM = n^* R^2, \quad (2.20)$$

dimana nilai k menunjukkan banyaknya observasi efektif dan R^2 adalah koefisien determinasi atau besarnya kontribusi varians *error*

yang dapat dijelaskan oleh data *time series* periode sebelumnya. H_0 akan ditolak jika nilai LM lebih besar dari $\chi^2_{(\alpha,n)}$ yang berarti bahwa data tidak bersifat heteroskedastisitas atau tidak terdapat efek ARCH-GARCH (Engle, 1982).

Uji Ljung-Box-Pierce digunakan untuk menguji asumsi *white noise* khususnya asumsi independen. Berikut merupakan hipotesis pada uji Ljung-Box-Pierce :

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0$$

$$H_1 : \text{minimal ada satu } \rho_k \neq 0, \text{ untuk } k = 1, 2, \dots, K$$

dengan statistik uji sebagai berikut :

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k} \quad (2.21)$$

dimana :

n = banyaknya pengamatan yang dilakukan,

$\hat{\rho}_k$ = taksiran autokorelasi *residual* pada lag ke- k .

Residual memenuhi asumsi independen jika gagal tolak H_0 yaitu

bila nilai $Q < \chi^2_{\alpha, df}$ atau nilai $p\text{-value} > \alpha$ (Ljung & Box, 1978).

Uji asumsi *white-noise* khususnya asumsi independen menggunakan uji Ljung-Box biasanya masih terdapat beberapa *lag residual* yang signifikan yang berarti bahwa *residual* masih belum sepenuhnya acak atau masih terdapat keterkaitan antara data satu dengan yang lain. Oleh karena itu, dalam beberapa penelitian juga digunakan *plot ACF residual* untuk menguji asumsi independen. Ketika sudah tidak ada nilai autokorelasi yang melebihi garis batas $\pm z_{\frac{\alpha}{2}} / \sqrt{N}$ maka dapat disimpulkan bahwa nilai *residual* yang

berdasarkan model yang diperoleh sudah memenuhi asumsi *white-noise* (Ramasubramanian, 2007).

Pengujian asumsi normalitas *residual* menggunakan uji Kolmogorov-Smirnov dengan hipotesis sebagai berikut :

H_0 : *residual* mengikuti asumsi distribusi normal

H_1 : *residual* tidak mengikuti asumsi distribusi normal

dengan nilai statistik uji :

$$D = \sup |F(a_t) - F_0(a_t)| \quad (2.22)$$

dimana :

$F(a_t)$ = fungsi peluang kumulatif *residual*,

$F_0(a_t)$ = fungsi peluang kumulatif distribusi normal atau fungsi yang dihipotesiskan,

\sup = nilai supremum (maksimum) dari semua hasil $|F(a_t) - F_0(a_t)|$.

Statistik uji D menghasilkan keputusan tolak H_0 jika $D > D_{(1-\alpha, n)}$ atau p -value kurang dari α , dengan n adalah ukuran sampel yang digunakan (Daniel, 1989).

2.5 Time Series Regression

Regresi merupakan salah satu analisis yang digunakan untuk mengetahui pola hubungan antara variabel respon dan variabel prediktor. Sehingga regresi dalam *time series* merupakan analisis yang digunakan untuk mengetahui hubungan variabel Y_t yang tergantung dengan fungsi waktu (t). Model pada *Time Series Regression* dipengaruhi oleh *trend*, pola *seasonal*, *calender variation*, hari-hari spesial, serta error yang autokorelasi (Soares & Medeiros, 2008).

Trend merupakan kecenderungan suatu data apakah memiliki pola meningkat atau menurun. Pengaruh *trend* pada *Time Series Regression* dinyatakan dengan t . Selanjutnya, untuk pola musiman (*seasonal*) pada data pemakaian beban listrik merupakan pola musiman berganda (*double seasonal*) yaitu musiman harian dan musiman mingguan. Pada pola musiman harian terdiri dari 48 variabel karena pada penelitian ini menggunakan data pemakaian beban listrik per setengah jam ($D_{1,t}, D_{2,t}, \dots, D_{48,t}$). Pada pola musiman mingguan terdiri dari 7 variabel yaitu hari Senin ($H_{1,t}$), Selasa ($H_{2,t}$), Rabu ($H_{3,t}$), Kamis ($H_{4,t}$), Jumat ($H_{5,t}$), Sabtu ($H_{6,t}$), dan Minggu ($H_{7,t}$). Interaksi antara jam dan hari diduga juga mempengaruhi pemakaian beban listrik di Jawa Timur, khususnya pada hari Jumat pukul 11.00 hingga pukul 13.00 ($J_{1,t}, J_{2,t}, \dots, J_{5,t}$),

hari Sabtu jam 00.30 hingga 24.00 ($S_{1,t}, S_{2,t}, S_{3,t} \dots, S_{48,t}$), dan hari Minggu pukul 00.30 hingga 24.00 ($M_{1,t}, M_{2,t}, M_{3,t} \dots, M_{48,t}$).

Berdasarkan uraian di atas, maka persamaan model dari *Time Series Regression* yang digunakan dalam penelitian ini yaitu :

$$\begin{aligned}
 Y_t = & \eta t + \alpha_1 D_{1,t} + \alpha_2 D_{2,t} + \alpha_3 D_{3,t} + \dots + \alpha_{48} D_{48,t} + \\
 & \gamma_1 H_{1,t} + \gamma_2 H_{2,t} + \gamma_3 H_{3,t} + \gamma_4 H_{4,t} + \dots + \gamma_7 H_{7,t} + \\
 & \omega_1 J_{1,t} + \omega_2 J_{2,t} + \omega_3 J_{3,t} + \omega_4 J_{4,t} + \omega_5 J_{5,t} + \\
 & \delta_1 S_{1,t} + \delta_2 S_{2,t} + \delta_3 S_{3,t} + \dots + \delta_{48} S_{48,t} + \\
 & \nu_1 M_{1,t} + \nu_2 M_{2,t} + \nu_3 M_{3,t} + \dots + \nu_{48} M_{48,t} + \varepsilon_t.
 \end{aligned} \tag{2.23}$$

Dari persamaan *Time Series Regression* di atas diketahui terdapat 157 variabel prediktor baik variabel *dummy* atau lag, dengan banyaknya variabel prediktor yang digunakan maka perlu dilakukan pemilihan variabel yang paling berpengaruh signifikan terhadap model. Sehingga digunakan metode *Random Forest* untuk memilih variabel prediktor berdasarkan rata-rata *variable important* yang paling besar, pembahasan lebih lanjut mengenai *Random Forest* dijelaskan pada sub bab 2.6.

2.5.1 Estimasi Parameter (*Ordinary Least Square*)

Ordinary Least Square (OLS) yaitu estimasi parameter dengan cara meminimumkan jumlah kuadrat *residual* atau error nilai-nilai observasi terhadap rata-ratanya. Persamaan model regresi linear sederhana adalah sebagai berikut (Draper & Smith, 1992) :

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \varepsilon \tag{2.24}$$

dimana,

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \\ \vdots \\ Y_n \end{bmatrix}, \mathbf{X} = \begin{bmatrix} 1 & D_{1,1} & D_{2,1} & \cdots & M_{48,1} \\ 2 & D_{1,2} & D_{2,2} & \cdots & M_{48,2} \\ 3 & D_{1,3} & D_{2,3} & \cdots & M_{48,3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ n & D_{1,n} & D_{2,n} & \cdots & M_{48,n} \end{bmatrix}, \boldsymbol{\beta} = \begin{bmatrix} \eta \\ \alpha_1 \\ \alpha_2 \\ \vdots \\ \nu_{48} \end{bmatrix}$$

kemudian diturunkan terhadap masing-masing parameternya sehingga didapatkan estimasi parameter sebagai berikut :

$$\hat{\beta} = (X'X)^{-1} X'Y. \quad (2.25)$$

2.5.2 Uji Signifikansi Parameter *Time Series Regression*

Pengujian signifikansi parameter *Time Series Regression* dilakukan secara parsial. Pengujian secara parsial merupakan pengujian yang dapat dilakukan sebanyak parameter dalam model regresi (Draper & Smith, 1992). Berikut hipotesis pengujian parameternya :

$$H_0 : \beta_w = 0$$

$$H_1 : \beta_w \neq 0, w = 1, 2, \dots, W$$

Untuk menguji signifikansi parameter dapat dihitung menggunakan statistik uji t dengan rumus sebagai berikut :

$$t_{hitung} = \frac{\hat{\beta}_w}{SE(\hat{\beta}_w)} \quad (2.26)$$

Nilai statistik uji t dikatakan tolak H_0 jika $|t_{hitung}| > t_{\alpha/2, n-p}$ atau tolak H_0 jika $p\text{-value}$ kurang dari nilai α yang digunakan, dengan n adalah ukuran sampel.

2.6 *Random Forest*

Metode *Random Forest* merupakan pengembangan dari metode CART (*Classification and Regression Tree*) dengan menerapkan metode *bootstrap aggregating (bagging)* dan *random feature selection*. Dalam *Random Forest* terdapat banyak *tree* yang terbentuk sehingga membentuk hutan (*forest*), kemudian analisis dilakukan pada kumpulan *tree* tersebut. Terdapat 2 tahapan untuk melakukan *Random Forest*, yaitu sebagai berikut (Breiman, 2001) :

1. *Preliminary elimination and ranking*

Tahapan ini diawali dengan melakukan penarikan *sample* acak berukuran z , dimana z adalah $2/3$ dari banyaknya data, kemudian membangun *tree* berdasarkan *sample* tersebut. *Tree* yang dibentuk berdasarkan pada prinsip *gini criterion* sebagai

pemilahnya. Selanjutnya, mengambil *sample* dengan ukuran z hingga s kali (*bootstrap*) dan membangun *tree* dari masing-masing *sample*. Kumpulan dari s *tree* akan membentuk sebuah *forest*, untuk memperoleh hasil yang lebih akurat dapat dilakukan penarikan *sample* lagi hingga membentuk r *forest*. Setelah terbentuk r *forest* maka dilakukan perhitungan nilai *variable important* (VI) untuk setiap variabel, nilai VI digunakan untuk meranking serta mengeliminasi variabel berdasarkan *threshold* yang ditentukan. Nilai *variable important* (VI) berkaitan dengan nilai error OOB (*out of bag*). Error OOB adalah error yang diperoleh dari hasil data *testing* yang diujikan terhadap model yang terbentuk dari hasil pembentukan setiap *tree*. Data *testing* ini merupakan data yang tidak termasuk dalam *sample bootstrap* pada langkah awal. Error OOB ditentukan melalui rumus berikut :

$$errOOB = \frac{1}{n-z} \sum_{i=1}^{n-z} (y_i - \hat{y}_i)^2 \quad (2.27)$$

dengan,

n = banyaknya data observasi

z = banyaknya *sample* yang digunakan untuk membentuk *tree* (data *testing*)

y_i = data *testing* ke- i

\hat{y}_i = prediksi data *testing* ke- i .

Kemudian nilai *variable important* (VI) diperoleh melalui persamaan berikut :

$$VI(X^j) = \frac{1}{s} \sum_{t=1}^s (errOOB_t^j - errOOB_t) \quad (2.28)$$

dimana,

$VI(X^j)$ = nilai *variable important* variabel ke- j

s = banyaknya *tree* yang dibangun

$errOOB_t^j$ = error pada *tree* ke- t tanpa melibatkan variabel ke- j

$errOOB_t$ = error pada *tree* ke- t yang melibatkan variabel ke- j .

Nilai $errOOB_t^j$ dihitung dengan membangun *tree* kembali berdasarkan *sample* yang telah diperoleh di awal, tetapi tidak melibatkan variabel ke- j . Langkah selanjutnya yaitu menyeleksi variabel berdasarkan nilai *mean* VI dengan *threshold* nilai standar deviasi VI terkecil.

2. *Variable selection*

Tahap *variable selection* digunakan untuk menentukan banyaknya variabel yang paling berpengaruh terhadap model prediksi. Pada tahap ini terbagi menjadi dua bagian yaitu *variable selection for interpretation* dan *variable selection for prediction*.

- *Variable selection for interpretation*

Merupakan tahapan untuk menyeleksi variabel yang paling berpengaruh dari hasil *preliminary elimination* berdasarkan nilai error OOB terkecil. *Tree* dibentuk kembali dengan penarikan *sample* acak sebanyak z dengan melibatkan satu variabel dengan nilai *mean* VI yang tertinggi. Kemudian menarik *sample* kembali dengan melibatkan 2 variabel yang terpenting berdasarkan nilai *mean* VI dari hasil *preliminary elimination*, begitu seterusnya hingga tidak tersisa variabel. Variabel yang terpilih pada tahap ini merupakan variabel yang memiliki nilai error OOB lebih kecil dari *threshold*, dimana *threshold* pada tahap ini yaitu nilai minimum error OOB ditambah dengan nilai standar deviasinya.

- *Variable selection for prediction*

Adalah tahapan eliminasi akhir berdasarkan hasil seleksi pada tahap *variable selection for interpretation*, untuk menentukan variabel yang paling berpengaruh dimana variabel tersebut dapat menurunkan error secara signifikan. Variabel dikatakan terpilih jika penurunan error OOB lebih besar daripada *threshold*, dengan *threshold* sebagai berikut :

$$\frac{1}{m - m'} \sum_{j=m'}^{m-1} |OOB(j+1) - OOB(j)| \quad (2.29)$$

dimana :

m = banyaknya variabel terseleksi pada tahap eliminasi

m' = banyaknya variabel terseleksi pada tahap interpretasi
 $OOB(j)$ = error OOB dari *random forest* yang dibangun menggunakan j variabel yang paling berpengaruh.

Simulasi *variable selection* dengan *Random Forest* menggunakan *The Hald Data* (Draper & Smith, 1992, hal : 348). Data tersebut terdiri dari 13 observasi dan 4 variabel prediktor. Berikut rincian *variable selection* dengan *Random Forest* pada *The Hald Data*.

1. *Preliminary elimination and ranking*

Langkah pertama yang dilakukan yaitu mengambil *sample* acak sebanyak z , dimana $z = 2/3 \times \text{banyaknya observasi} = 2/3 \times 13 = 9$. Berdasarkan *sample* tersebut lalu dibangun *tree* berdasarkan *gini criterion* dengan tahapan berikut (Komalasari, 2007).

- a. Menentukan semua kemungkinan penyekat (split) pada tiap variabel prediktor. Pada variabel kontinu x_j , penyekat yang diperbolehkan adalah $x_j < c$ dan $x_j \geq c$, dimana c adalah nilai tengah antara dua nilai pada variabel prediktor x_j yang telah berurut. Jadi jika x_j mempunyai z pengamatan yang berbeda, maka akan ada $z-1$ kemungkinan penyekat (split). Misal pengambilan *sample* yang pertama diperoleh data seperti yang disajikan pada Tabel 2.4. Maka untuk menentukan kemungkinan penyekat pada tiap variabel prediktor perlu dilakukan pengurutan data pada variabel yang bersesuaian. Dari hasil pengurutan nilai variabel X_1 pada Tabel 2.5 diperoleh 12 kemungkinan penyekat (split) yaitu $X_1 < 2$; $X_1 \geq 2$; $X_1 < 5$; $X_1 \geq 5$; $X_1 < 8,5$; $X_1 \geq 8,5$; $X_1 < 10,5$; $X_1 \geq 10,5$; $X_1 < 11$; $X_1 \geq 11$; $X_1 < 16$; dan $X_1 \geq 16$. Berdasarkan setiap kemungkinan tersebut kemudian dihitung jumlah kuadrat *residual* dengan rumus berikut.

$$JKS(t) = \sum_{i=1}^u \left(y_{i(t)} - \bar{y}_{(t)} \right)^2 \quad (2.30)$$

dimana,

$y_{i(t)}$ = nilai variabel respon ke- i pada simpul ke- t

$\bar{y}_{(t)}$ = nilai rata-rata variabel respon pada simpul ke- t

u = banyaknya data pada simpul ke- t .

Tabel 2.4 Data *Sample Pertama The Hald Data*

X_1	X_2	X_3	X_4	Y
7	52	6	33	95,9
3	71	17	6	102,7
21	47	4	26	115,9
1	29	15	52	74,3
7	26	6	60	78,5
11	31	8	47	87,6
10	68	8	12	109,4
11	66	9	12	113,3
11	56	8	20	104,3

Tabel 2.5 Data *Sample* X_1 yang Telah Diurutkan.

X_1	Y
1	74,3
3	102,7
7	95,9
7	78,5
10	109,4
11	87,6
11	113,3
11	104,3
21	115,9

$$\begin{aligned}
 JKS(1) &= \sum_{i=1}^9 \left(y_{i(1)} - \bar{y}_{(1)} \right)^2 \\
 &= \sum_{i=1}^9 \left(y_{i(1)} - 97,9889 \right)^2 \\
 &= (74,3 - 97,9889)^2 + \dots + (115,9 - 97,9889)^2 \\
 &= (-23,6889)^2 + \dots + (17,9111)^2 \\
 &= 1800,75
 \end{aligned}$$

Setelah menghitung jumlah kuadrat *residual* simpul selanjutnya menghitung jumlah kuadrat *residual* simpul kiri ($JKS(t_L)$) dan kanan ($JKS(t_R)$). Simpul 1 kiri merupakan data

dengan kriteria $X_1 < 2$, sedangkan simpul 1 kanan adaah data dengan kriteria $X_1 \geq 2$ seperti ditunjukkan melalui warna yang berbeda pada Tabel 2.5.

$$\begin{aligned}
 JKS(1_L) &= \sum_{i=1}^1 \left(y_{i(1_L)} - \bar{y}_{(1_L)} \right)^2 \\
 &= (74,3 - 74,3)^2 \\
 &= 0 \\
 JKS(1_R) &= \sum_{i=1}^8 \left(y_{i(1_R)} - \bar{y}_{(1_R)} \right)^2 \\
 &= \sum_{i=1}^8 \left(y_{i(1_R)} - 100,95 \right)^2 \\
 &= (102,7 - 100,95)^2 + \dots + (115,9 - 100,95)^2 \\
 &= (1,75)^2 + \dots + (14,95)^2 \\
 &= 1169,44
 \end{aligned}$$

- b. Menentukan fungsi penyekat (split) pada setiap kemungkinan simpul. Fungsi penyekat dengan nilai paling rendah digunakan sebagai kandidat terpilih pada variabel prediktor yang bersesuaian. Fungsi penyekat dihitung berdasarkan rumus berikut.

$$\psi(s, t) = JKS(t) - \{ JKS(t_L) + JKS(t_R) \} \quad (2.31)$$

dengan s merupakan kemungkinan penyekat yang digunakan pada simpul t . Sehingga, nilai fungsi penyekat 2 variabel X_1 pada simpul 1 adalah :

$$\begin{aligned}
 \psi(2, 1) &= JKS(1) - \{ JKS(1_L) + JKS(1_R) \} \\
 &= 1800,75 - \{ 0 + 1169,44 \} \\
 &= 631,309
 \end{aligned}$$


Perhitungan yang sama pada setiap penyekat dilakukan seperti langkah di atas untuk memperoleh nilai fungsi penyekat. Hasil perhitungan fungsi penyekat untuk setiap kemungkinan penyekat ditampilkan pada Tabel 2.6. Penyekat yang terpilih pada variabel X_1 adalah fungsi

penyekat dengan hasil yang paling rendah, yaitu pada nilai $X_1 < 5$ dan $X_1 \geq 5$.

Tabel 2.6 Hasil Fungsi Penyekat pada Variabel X_1 .


Kemungkinan Penyekat	$\psi(s, t)$
$X_1 < 2$	631,309
$X_1 \geq 2$	
$X_1 < 5$	231,529
$X_1 \geq 5$	
$X_1 < 8,5$	740,139
$X_1 \geq 8,5$	
$X_1 < 10,5$	382,230
$X_1 \geq 10,5$	
$X_1 < 11$	382,230
$X_1 \geq 11$	
$X_1 < 16$	360,909
$X_1 \geq 16$	

- c. Perhitungan pada poin a dan b diatas diulang kembali menggunakan variabel X_2 , X_3 , dan X_4 hingga diperoleh penyekat terpilih pada setiap variabel. Dari keempat penyekat terpilih kemudian dibandingkan nilai fungsi penyekatnya. Penyekat terpilih dengan dengan fungsi penyekat terkecil digunakan sebagai simpul 1. Kemudian untuk menentukan simpul 2 dan seterusnya menggunakan data berdasarkan kriteria pada simpul 1 dengan langkah-langkah di atas. pembentukan *tree* berhenti jika anggota dalam simpul hanya satu observasi. Berdasarkan *sample* pada Tabel 2.5 diperoleh *tree* yang disajikan pada Gambar 2.4.



Gambar 2.4 *Regression Tree Sample 1.*


Setelah terbentuk 1 *tree* kemudian mengambil *sample* secara acak sebanyak 9 observasi sebanyak 5 kali dan membuat 5 *regression tree* berdasarkan masing-masing *sample* tersebut. kelima *tree* yang terbentuk menyusun sebuah *forest*. Proses yang sama diulangi hingga terbentuk *r forest*, pada simulasi ini menggunakan 5 *forest*. Langkah selanjutnya yaitu menentukan nilai $errOOB_t$ yang diperoleh dari data *testing* (4 data yang tidak termasuk dalam penarikan *sample*). Kemudian $errOOB_t^j$ dihitung dengan membangun *tree* kembali berdasarkan *sample* yang telah terambil sebelumnya tanpa melibatkan variabel ke- j . Sehingga dapat dihitung nilai VI untuk masing-masing variabel menggunakan persamaan 2.28 dan diperoleh plot *mean VI* beserta *threshold* yang ditunjukkan dengan garis merah pada Gambar 2.5. Jadi Variabel yang pertama kali terseleksi adalah X_4 karena memiliki nilai *mean VI* yang paling besar. Kemudian terpilih variabel X_1 dan X_2 .



Gambar 2.5 Plot Mean VI Hasil Seleksi Tahap 1 *Random Forest*.

2. Variable selection for interpretation


Tahapan ini diawali dengan membangun *tree* berdasarkan *sample* acak berukuran z yang menyertakan satu variabel yang paling penting berdasarkan nilai *mean* VI tertinggi yaitu X_4 . Kemudian menarik *sample* kembali dengan menyertakan variabel X_4 dan X_1 , yang terakhir mengambil *sample* berukuran z yang menyertakan variabel X_4 , X_1 , dan X_2 . Dari *sample* yang diperoleh kemudian dibentuk *tree* berdasarkan langkah pada tahap 1 dan menghitung nilai *errOOB* menggunakan persamaan 2.27. Dari perhitungan tersebut kemudian ditentukan nilai minimum *errOOB* ditambah dengan nilai standar deviasi *errOOB* yang digunakan sebagai *threshold*. Plot nilai *errOOB* tiap variabel disajikan pada Gambar 2.6. Berdasarkan Gambar tersebut diketahui bahwa dari 3 variabel yang terseleksi pada tahap pertama kemudian terseleksi kembali menjadi 2 variabel yaitu X_4 dan X_1 .



Gambar 2.6 Plot *errOOB* Hasil Seleksi Tahap 2 *Random Forest*.

3. *Variable selection for prediction*

Berdasarkan hasil seleksi pada tahap kedua diperoleh 2 variabel terpilih yaitu X_4 dan X_1 . Dari kedua variabel tersebut kemudian diseleksi kembali menggunakan *threshold* yang berbeda yaitu pada persamaan 2.29. Variabel yang terseleksi merupakan variabel yang mampu menurunkan *errOOB* lebih besar dari *threshold*. Pada Gambar 2.6 dengan menyertakan variabel X_4 ke dalam model diperoleh nilai *errOOB* sebesar 90, kemudian dengan menyertakan variabel X_4 dan X_1 diperoleh penurunan *errOOB* yang cukup besar menjadi 40. Lalu dengan penambahan variabel X_4 , X_1 , dan X_2 terjadi kenaikan *errOOB* sehingga variabel yang terseleksi pada tahap ketiga yaitu X_4 dan X_1 . Plot *errOOB* hasil seleksi tahap ketiga disajikan pada Gambar 2.7



Gambar 2.7 Plot *errOOB* Hasil Seleksi Tahap 3 *Random Forest*.

Jadi, berdasarkan langkah-langkah seleksi variabel dengan *Random Forest* pada *The Hald Data* diperoleh hasil bahwa variabel yang terpilih yaitu X_4 dan X_1 . Proses seleksi variabel menggunakan metode *Stepwise* juga dilakukan pada *The Hald Data*. Penjelasan tahapan metode *stepwise* dijelaskan pada sub bab selanjutnya. Pada Tabel 2.7 disajikan hasil urutan variabel terpilih menggunakan *Random Forest* dan *Stepwise*.

Tabel 2.7 Hasil Variabel Terpilih Menggunakan *Random Forest* dan *Stepwise*..

<i>Random Forest</i>				<i>Stepwise</i>	
Tahap 1	Tahap 2	Tahap 3	<i>errOOB</i>	Variabel	MSE
X_4	X_4	X_4	90	X_4	80,4
X_1	X_1	X_1	42*	X_1	7,5*
X_2			48**		

* Nilai *errOOB* atau MSE dengan menyertakan variabel X_4 dan X_1 ke dalam model.

** Nilai *errOOB* dengan menyertakan variabel X_4 , X_1 , dan X_2 ke dalam model.

Berdasarkan hasil pada Tabel 2.7 diketahui bahwa prinsip seleksi variabel antara metode *Random Forest* dan *Stepwise* adalah sama yaitu meminimumkan *error*. Dari tabel tersebut juga menunjukkan bahwa variabel yang pertama kali terseleksi pada metode *Random Forest* dan *Stepwise* adalah X_4 . Pada hasil akhir tahap 3 *Random Forest* diperoleh variabel terseleksi yang sama seperti pada metode *Stepwise*.

Berdasarkan uraian di atas mengenai langkah-langkah serta simulasi seleksi variabel menggunakan *Random Forest*, berikut ringkasan algoritma *Random Forest* untuk setiap tahapan.

Algoritma 1. *Preliminary elimination and ranking*

1. Membangun *regression tree*

- Mengambil *sample* acak.
- Menentukan simpul akar yang meminimumkan jumlah kuadrat *residual* dari seluruh kemungkinan simpul akar yang terbentuk.
- Mengulangi langkah 1.b hingga anggota dalam setiap simpul hanya satu observasi.

2. Mengulangi langkah 1 hingga s kali sehingga membentuk 1 *forest* (kumpulan dari s *regression tree*).
3. Menghitung nilai $errOOB_t$ yang melibatkan seluruh variabel berdasarkan *regression tree* yang terbentuk pada langkah 1.
4. Membangun *regression tree* seperti langkah 1 tanpa melibatkan variabel ke- j .
5. Menghitung nilai $errOOB_t^j$ tanpa melibatkan variabel ke- j berdasarkan *regression tree* yang terbentuk pada langkah 4.
6. Menghitung nilai *variable important* (VI) variabel ke- j dalam 1 *forest* berdasarkan nilai rata-rata selisih $errOOB_t$ dengan $errOOB_t^j$.
7. Mengulangi langkah 1 dan 2 hingga terbentuk r *forest*, kemudian menghitung nilai *variable important* (VI) variabel ke- j pada setiap *forest* lalu menghitung rata-rata *variable important* (VI) variabel ke- j .
8. Menentukan *threshold* untuk menyeleksi variabel berdasarkan nilai rata-rata *variable important* (VI). *Threshold* yang digunakan adalah nilai standar deviasi VI terkecil. Variabel dengan rata-rata *variable important* (VI) yang lebih besar dari *threshold* akan terseleksi menuju tahap selanjutnya.

Algoritma 2. *Variable selection for interpretation*

1. Membangun *regression tree* yang melibatkan j variabel yang paling berpengaruh dalam model berdasarkan nilai rata-rata VI. Dimana $j = 1, 2, \dots, m$ dengan m adalah banyaknya variabel yang terseleksi dari tahap 1 (*Preliminary elimination and ranking*).
2. Mengitung nilai $errOOB$ dari setiap *regression tree* yang terbentuk.
3. Menyeleksi variabel dari hasil seleksi tahap 1 dengan kriteria nilai $errOOB$ lebih kecil dari *threshold*, dimana *threshold* adalah nilai minimum $errOOB$ ditambah dengan nilai standar deviasinya.

Algoritma 3. *Variable selection for prediction*

1. Menghitung penurunan *errOOB* yang melibatkan j variabel yang paling berpengaruh terhadap model.
2. Menyeleksi variabel hasil seleksi tahap 2 dengan kriteria penurunan *errOOB* lebih besar dari *threshold*. *Threshold* yang digunakan sesuai pada persamaan 2.29.

2.7 Stepwise

Metode *Stepwise* merupakan salah satu metode dengan algoritma sederhana yang digunakan untuk menyeleksi variabel berdasarkan semua kemungkinan model regresi yang terbentuk. Prinsip dari metode seleksi ini yaitu dengan menambahkan atau menghapus variabel berdasarkan hasil regresinya. Metode *Stepwise* menggabungkan 2 tahapan yaitu tahap *forward stepwise selection* dan tahap *backward elimination*.

Tahap *forward stepwise selection* merupakan tahap untuk memilih variabel yang akan dimasukkan ke dalam model. Pemilihan variabel ini berdasarkan nilai koefisien korelasi yang paling besar terhadap variabel respon. Koefisien korelasi antara variabel prediktor x_j dan variabel respon y dihitung dengan persamaan sebagai berikut.

$$\rho_{x_j y} = \frac{\sum_{i=1}^n (x_{ji} - \bar{x})(y_i - \bar{y})}{(n-1)S_{x_j} S_y} \quad (2.32)$$

$$\text{dimana, } S_{x_j} = \sqrt{\frac{\sum_{i=1}^n (x_{ji} - \bar{x})^2}{n-1}} \text{ dan } S_y = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n-1}} .$$

Setelah memasukkan variabel ke dalam model kemudian dilakukan tahap *backward elimination* dengan menghitung nilai estimasi model regresi. Jika variabel yang dimasukkan ke dalam model tersebut berpengaruh signifikan maka variabel tersebut tetap dipertahankan. Tetapi jika tidak signifikan dalam model maka

variabel tersebut dikeluarkan dari model. Selanjutnya mengulangi tahap *forward stepwise selection* dengan menghitung korelasi parsial antara variabel prediktor x_k dan variabel respon y jika diketahui bahwa variabel x_j telah masuk ke dalam model. Perhitungan koefisien korelasi parsial tersebut dihitung melalui rumus berikut.


$$\rho_{x_j, y | x_k} = \frac{\rho_{x_j, y} - \rho_{x_j, x_k} \rho_{y, x_k}}{\sqrt{1 - \rho_{x_j, x_k}^2} \sqrt{1 - \rho_{y, x_k}^2}}. \quad (2.33)$$

Kemudian dipilih variabel yang akan dimasukkan ke dalam model dengan nilai koefisien korelasi parsial terbesar. Setelah itu model dievaluasi berdasarkan prinsip *backward elimination*. Kedua tahap ini akan terus berulang hingga sudah tidak terdapat variabel yang masuk maupun keluar dari model (Rawlings, Pantula & Dickey, 1998).

2.8 Window Time

Window time berkaitan erat dengan konsep *drift* (Sun & Li, 2011). Terdapat lima macam jenis pembagian *window* yang digunakan dalam pemodelan yaitu *full memory*, *no memory*, *fixed size*, *adaptable size*, dan *batch selection*. Pada penelitian ini jenis *window time* yang digunakan yaitu *fixed size*.

Fixed size window time adalah salah satu jenis *window time* yang memiliki jumlah observasi sama untuk setiap *window* dengan *current time point* yang berbeda-beda (Klinkenberg, 2004). Berdasarkan ilustrasi yang ditampilkan pada Gambar 2.8 dapat diketahui bahwa banyaknya observasi untuk setiap *window* sama yaitu 2 tahun. Dimana *window* 1 mencakup data pada tahun ke- t dan $t + 1$, kemudian *window* 2 mencakup data pada tahun ke- $t + 1$ dan $t + 2$, begitu seterusnya hingga sebanyak *window* yang diinginkan.



Sumber : Klinkenberg (2004)

Gambar 2.8 Fixed Size Window Time 2 Tahun.

2.9 Pemilihan Model Terbaik

Pemilihan model terbaik menggunakan kriteria *out-sample* yaitu RMSE (*Root Mean Square Error*). RMSE merupakan nilai akar dari rata-rata *residual* yang dikuadratkan. Dalam menentukan *residual* dari ramalan l langkah kedepan dapat dihitung dengan rumus berikut.

$$e_l = Y_{n+l} - \hat{Y}_n(l). \quad (2.34)$$

Berdasarkan persamaan (2.30), maka nilai RMSE ditentukan dari rumus matematis berikut (Wei, 2006) :

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\frac{\sum_{l=1}^M e_l^2}{M}} \quad (2.35)$$

dengan,

Y_{n+l} = pengamatan pada waktu ke- $(n + l)$

$\hat{Y}_n(l)$ = ramalan l langkah kedepan

n = banyaknya pengamatan pada data *in-sample*.

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder pemakaian beban listrik dari anak cabang PT. PLN (Persero) yaitu PLN P2B (Penyaluran dan Pusat Pengaturan Beban) wilayah Jawa Timur dengan periode 24 September 2015 hingga 30 September 2016. Variabel respon yang digunakan adalah data pemakaian beban listrik per-setengah jam di wilayah Jawa Timur. Pada metode *Time Series Regression*, variabel prediktor yang digunakan meliputi *trend*, pola *seasonal* harian, pola *seasonal* mingguan, dan interaksi antara pola *seasonal* harian dan mingguann dengan rincian variabel sebagai berikut.

Tabel 3.1 Variabel pada Model *Time Series Regression*.

Variabel	Jenis	Keterangan
Y_t	Respon	Pemakaian beban listrik (MW)
t	<i>Trend</i>	Pola <i>trend</i>
$D_{1,t}$	<i>Seasonal</i> harian	Jam 0.30
$D_{2,t}$		Jam 1.00
\vdots		\vdots
$D_{48,t}$		Jam 24.00
$H_{1,t}$	<i>Seasonal</i> mingguan	Hari Senin
$H_{2,t}$		Hari Selasa
\vdots		\vdots
$H_{7,t}$		Hari Minggu
$J_{1,t}$	Interaksi antara <i>seasonal</i> harian dan <i>seasonal</i> mingguan	Hari Jumat jam 11.00
\vdots		\vdots
$J_{3,t}$		Hari Jumat jam 13.00
$S_{1,t}$		Hari Sabtu jam 0.30
\vdots		\vdots
$S_{48,t}$		Hari Sabtu jam 24.00
$M_{1,t}$		Hari Minggu jam 0.30
\vdots		\vdots
$M_{48,t}$		Hari Minggu jam 24.00

Sedangkan pada model *Double Seasonal* ARIMA variabel prediktor yang digunakan merupakan lag-lag yang mempengaruhi pemakaian beban listrik dengan rincian berikut :

Tabel 3.2 Variabel pada Model *Double Seasonal* ARIMA.

Variabel	Jenis	Keterangan
Y_t	Respon	Pemakaian beban listrik (MW)
Y_{t-1}	Prediktor	Lag ke-1
Y_{t-2}		Lag ke-2
Y_{t-3}		Lag ke-3
Y_{t-4}		Lag ke-4
\vdots		\vdots
Y_{t-u}		Lag ke- u

3.2 Langkah Analisis

Pada penelitian ini proses analisis data terbagi menjadi dua bahasan, yang pertama mengenai peramalan pemakaian beban listrik jangka pendek di wilayah Jawa Timur pada metode *Time Series Regression* dan *Double Seasonal* ARIMA tanpa pemilihan input menggunakan *Random Forest* dan yang kedua mengenai peramalan pemakaian beban listrik jangka pendek di wilayah Jawa Timur pada metode *Time Series Regression* dan *Double Seasonal* ARIMA dengan pemilihan input menggunakan *Random Forest*. Pada penelitian ini juga ditambahkan seleksi variabel menggunakan metode *Stepwise* sebagai pembanding. Berikut uraian langkah analisis yang dilakukan.

1. Mendeskripsikan karakteristik pemakaian beban listrik di wilayah Jawa Timur menggunakan keseluruhan data yaitu tanggal 24 September 2015 hingga 30 September 2016.
2. Menentukan model peramalan menggunakan metode *Time Series Regression* dengan langkah sebagai berikut :
 - a. Menentukan data *in-sample* dan *out-sample*, data *in-sample* dipilih pada tanggal 24 September 2015 sampai 23 September 2016 sedangkan data *out-sample* selama 1 minggu yaitu pada tanggal 24-30 September 2016.

- b. Menentukan model dengan meregresikan variabel respon berupa pemakaian beban listrik di Jawa Timur dengan variabel *dummy*.
 - c. Menaksir parameter dan menguji signifikansi parameter.
 - d. Menguji residual apakah memenuhi asumsi *white noise* menggunakan Uji Ljung-Box dan pengujian distribusi normal menggunakan Uji *Kolmogorov-Smirnov*.
 - e. Memilih model terbaik dengan kriteria *out-sample* menggunakan nilai RMSE yang terkecil.
3. Menentukan model peramalan menggunakan metode *Double Seasonal* ARIMA dengan langkah sebagai berikut :
- a. Menentukan data *in-sample* dan *out-sample*, data *in-sample* dipilih pada tanggal 24 September 2015 sampai 23 September 2016 sedangkan data *out-sample* selama 1 minggu yaitu pada tanggal 24-30 September 2016.
 - b. Melakukan pengecekan stasioneritas data pemakaian beban listrik di Jawa Timur baik dalam *mean* maupun variansnya). Jika data tidak stasioner terhadap *mean* maka dilakukan *differencing*, sedangkan jika data tidak stasioner terhadap varians maka dilakukan transformasi berdasarkan nilai λ pada analisa Box-Cox.
 - c. Menentukan model berdasarkan plot ACF dan PACF yang telah stasioner.
 - d. Melakukan estimasi parameter model dan menguji signifikansi parameter model.
 - e. Melakukan pengujian diagnosa untuk semua parameter yang signifikan, meliputi uji *white noise* residual menggunakan Uji Ljung-Box dan pengujian distribusi normal dengan Uji *Kolmogorov-Smirnov*.
 - f. Memilih model terbaik dengan kriteria *out-sample* menggunakan nilai RMSE yang terkecil.
4. Menentukan input (*prediktor*) yang paling berpengaruh pada model *Time Series Regression* menggunakan metode *Random Forest*. Pada analisis ini, data *in-sample* yang digunakan mulai tanggal 25 Agustus 2016 hingga 23 September 2016 dan data *out-sample* selama 1 minggu yaitu pada tanggal 24-30


September 2016. Metode ini terdiri dari tiga tahap yaitu *preliminary elimination and ranking*, *variable selection for interpretation*, dan *variable selection for prediction*. Rincian langkah-langkah setiap tahap yaitu sebagai berikut :

- a. Mengambil *sample* acak berukuran z dengan pengembalian kemudian membangun *s tree* berdasarkan *sample* tersebut sehingga membentuk sebuah *forest*.
 - b. Mengulangi langkah pada poin 4.a di atas sebanyak r sehingga terbentuk *r forest*.
 - c. Menghitung nilai *variable important* (VI) untuk setiap variabel serta menentukan *threshold* yang digunakan untuk menyeleksi variabel berdasarkan nilai VI yang lebih besar dari *threshold* (tahap *preliminary elimination and ranking*).
 - d. Menyeleksi variabel yang paling berpengaruh berdasarkan hasil pada tahap *preliminary elimination* berdasarkan nilai OOB (*out of bag*) terkecil. (tahap *variable selection for interpretation*)
 - e. Menyeleksi variabel yang paling berpengaruh berdasarkan hasil pada tahap *variable selection for interpretation* berdasarkan penurunan error OOB yang lebih besar dari *threshold* (tahap *variable selection for prediction*). Tahap ini merupakan tahap akhir dari proses seleksi variabel menggunakan *Random Forest* yang menghasilkan *output* berupa variabel yang signifikan mempengaruhi model.
5. Menentukan model peramalan berdasarkan hasil seleksi variabel pada langkah 4 menggunakan metode *Time Series Regression* menggunakan langkah-langkah pada poin 2.
 6. Menentukan input (*prediktor*) yang paling berpengaruh pada model *Double Seasonal ARIMA* menggunakan metode *Random Forest* dengan langkah-langkah pada poin 4.
 7. Menentukan model peramalan berdasarkan hasil seleksi variabel pada langkah 5 menggunakan metode *Double Seasonal ARIMA* menggunakan langkah-langkah pada poin 3.
 8. Menentukan input (*prediktor*) yang paling berpengaruh pada model *Time Series Regression* dan *Double Seasonal ARIMA* menggunakan metode *Stepwise*. Metode ini menggabungkan

dua tahap yaitu tahap *forward stepwise selection* dan tahap *backward elimination*. Rincian langkah-langkah setiap tahap yaitu sebagai berikut :

- a. Tahap *forward stepwise selection* merupakan tahap untuk memilih variabel yang akan dimasukkan ke dalam model. Pemilihan variabel ini berdasarkan nilai koefisien korelasi yang paling besar terhadap variabel respon.
 - b. Tahap *backward elimination* dilakukan untuk mengevaluasi variabel yang telah dipilih pada tahap *forward stepwise selection* dengan menghitung nilai estimasi model regresi. Jika variabel yang dimasukkan ke dalam model tersebut berpengaruh signifikan terhadap model, maka variabel tersebut tetap dipertahankan. Tetapi jika tidak signifikan dalam model maka variabel tersebut dikeluarkan dari model.
 - c. Kedua tahap tersebut akan terus berulang hingga sudah tidak terdapat variabel yang masuk maupun keluar dari model.
9. Menentukan model peramalan berdasarkan hasil seleksi variabel pada langkah 8 menggunakan metode *Time Series Regression* menggunakan langkah-langkah pada poin 2.
 10. Menentukan model peramalan berdasarkan hasil seleksi variabel pada langkah 8 menggunakan metode *Double Seasonal ARIMA* menggunakan langkah-langkah pada poin 3.
 11. Membandingkan ketepatan peramalan pemakaian beban listrik antara model yang menggunakan proses pemilihan input menggunakan *Random Forest* dan *Stepwise* peramalan yang tidak menggunakan proses seleksi variabel. Perbandingan peramalan menggunakan kriteria *out-sample* yaitu nilai RMSE yang terkecil.

Berdasarkan tahapan penelitian di atas, diagram alir dari penelitian ini secara umum ditampilkan pada Gambar 3.1.



Gambar 3.1 Diagram Alir Tahapan Penelitian.

BAB IV

ANALISIS DAN PEMBAHASAN

4.1 Karakteristik Pemakaian Beban Listrik di Wilayah Jawa Timur

Pemakaian beban listrik dipengaruhi oleh kebutuhan masing-masing pelanggan. Kebutuhan aktivitas pelanggan yang beragam menyebabkan naik turunnya konsumsi listrik di Jawa Timur. Dari keseluruhan data pemakaian beban listrik mulai 24 September 2015 hingga 30 September 2016 terdiri dari 17904 observasi dengan rata-rata pemakaian sebesar 4071 MW dan standar deviasi 487,9 MW. Berdasarkan Tabel 4.1 diketahui bahwa rata-rata konsumsi listrik di Jawa Timur paling tinggi (*peak load*) terjadi pada pukul 18.30 sebesar 4747,5 MW dan paling rendah pada pukul 07.00 sebesar 3537,6 MW. Hal ini diduga karena pada pukul 07.00 banyak masyarakat yang bersiap-siap untuk berangkat kerja sehingga tidak banyak yang menggunakan peralatan elektronik seperti televisi, lampu, dan komputer sehingga konsumsi listrik sedikit. Sedangkan pada pukul 18.30 masyarakat sudah kembali ke rumah dan menggunakan berbagai peralatan elektronik sehingga penggunaan beban listrik mencapai puncaknya.

Naik turunnya penggunaan listrik selain dipengaruhi oleh jam pemakaian juga dipengaruhi oleh hari. Dari Tabel 4.2 diketahui bahwa rata-rata penggunaan beban listrik yang paling tinggi pada hari Selasa yaitu sebesar 4220,6 MW sedangkan konsumsi listrik terendah pada hari Minggu dengan rata-rata penggunaan sebesar 3646,2 MW. Secara umum penggunaan beban listrik pada hari kerja lebih tinggi dibanding akhir pekan (Sabtu dan Minggu). Karena pada hari kerja banyak kantor-kantor dan instansi pemerintah yang menggunakan listrik untuk kebutuhannya, misalnya menyalakan lampu, AC, LCD, dan sebagainya. Sedangkan pada akhir pekan kebanyakan masyarakat yang bekerja menghabiskan harinya di rumah sehingga konsumsi listrik tidak sebesar pada saat hari kerja.

Tabel 4.1 Rata-rata dan Standar Deviasi Konsumsi Listrik
Per Setengah Jam.

Jam	Pengamatan	Rata-rata	St.Deviasi
0.30	373	3794,2	249,1
1.00	373	3753,6	249,4
1.30	373	3713,0	250,6
2.00	373	3676,1	248,3
2.30	373	3646,4	247,3
3.00	373	3625,0	245,7
3.30	373	3634,2	251,1
4.00	373	3686,0	251,6
4.30	373	3779,2	250,9
5.00	373	3860,3	256,8
5.30	373	3818,1	268,9
6.00	373	3679,6	275,1
6.30	373	3567,0	261,2
7.00	373	3537,6	266,2
7.30	373	3686,0	320,8
8.00	373	3816,1	373,3
8.30	373	3962,3	427,9
9.00	373	4025,0	448,1
9.30	373	4078,5	460,0
10.0	373	4137,8	468,6
10.30	373	4181,2	476,3
11.00	373	4194,6	478,1
11.30	373	4133,4	450,8
12.00	373	4007,1	404,8
12.30	373	4009,4	405,8
13.00	373	4125,9	455,3
13.30	373	4246,2	505,4
14.00	373	4232,8	504,1
14.30	373	4206,7	496,3
15.00	373	4169,9	480,6
15.30	373	4167,6	461,9
16.00	373	4139,4	426,4
16.30	373	4156,5	396,9
17.00	373	4248,6	373,3
17.30	373	4557,8	373,0
18.00	373	4729,3	319,1


Tabel 4.1 Rata-rata dan Standar Deviasi Konsumsi Listrik Per Setengah Jam (Lanjutan).

Jam	Pengamatan	Rata-rata	St.Deviasi
18.30	373	4747,5	297,7
19.00	373	4721,4	288,4
19.30	373	4714,7	291,0
20.00	373	4686,1	284,1
20.30	373	4620,4	276,2
21.00	373	4502,1	269,6
21.30	373	4332,3	264,6
22.00	373	4181,0	264,3
22.30	373	4119,3	270,3
23.00	373	4012,5	261,4
23.30	373	3930,3	258,6
24.00	373	3857,7	252,8

Tabel 4.2 Rata-rata dan Standar Deviasi Konsumsi Listrik Per Hari.

Hari	Pengamatan	Rata-rata	St.Deviasi
Senin	2544	4093,1	529,5
Selasa	2544	4220,6	440,3
Rabu	2544	4190,1	458,2
Kamis	2592	4193,8	480,4
Jumat	2592	4170,9	473,5
Sabtu	2544	3978,1	371,8
Minggu	2544	3646,2	371,7


Time series plot dari pemakaian beban listrik di Jawa Timur disajikan pada Gambar 4.1. Secara umum sejak tanggal 24 September 2015 hingga 30 September 2016 terjadi pola pemakaian listrik yang cenderung meningkat. Selain itu, dari gambar tersebut juga menunjukkan perbedaan konsumsi listrik pada hari biasa, hari libur nasional, bulan puasa, dan lebaran. Pemakaian listrik cenderung rendah pada hari libur nasional, bulan puasa, dan lebaran. Sehingga dapat disimpulkan bahwa hari libur nasional, bulan puasa, dan lebaran mempengaruhi besar kecilnya konsumsi listrik masyarakat di Jawa Timur.




Gambar 4.1 *Time Series Plot* Pemakaian Beban Listrik pada 24 September 2015 hingga 30 September 2016.

Berdasarkan penjelasan Gambar 4.1 yang menunjukkan bahwa pemakaian beban listrik dipengaruhi oleh hari libur nasional, maka pada Gambar 4.2 ditampilkan perbandingan *line plot* antara konsumsi listrik pada hari biasa dan hari libur nasional. Hari libur nasional pada gambar tersebut merupakan hari libur nasional baik keagamaan maupun bukan yang tidak jatuh pada hari Minggu. Gambar 4.2(b) menunjukkan bahwa secara umum pola pemakaian listrik masyarakat Jawa Timur saat libur nasional relatif sama. Tetapi berbeda halnya pada hari biasa yang memiliki pola berbeda antara hari kerja dan akhir pekan. Konsumsi listrik cenderung lebih rendah di akhir pekan dibanding pada hari kerja karena kantor, instansi pemerintah, dan kegiatan industri sebagian besar libur.


Hari-hari kerja mulai Senin hingga Kamis, konsumsi listrik relatif sama seperti ditunjukkan pada Gambar 4.2(a). Namun pada hari Senin pagi mulai pukul 0.30 hingga 5.00 dan Jumat pukul 12.00 hingga 12.30 menunjukkan pola pemakaian listrik yang cenderung lebih rendah dari hari kerja lainnya untuk jam yang sama. Pada hari Senin pagi mulai pukul 0.30 hingga 5.00 pemakaian listrik lebih rendah diduga disebabkan oleh aktifitas masyarakat belum terlalu banyak karena masih terbawa oleh suasana akhir pekan. Konsumsi listrik mulai meningkat signifikan pada pukul 7.00 karena sebagian besar masyarakat memulai aktifitasnya untuk bekerja. Sedangkan pada hari Jumat pukul 12.00 hingga 12.30 konsumsi listrik yang lebih rendah dari hari kerja lainnya karena sebagian besar masyarakat di Jawa Timur sedang menunaikan ibadah shalat Jumat sehingga pekerjaan dihentikan. Gambar 4.2 (c) menunjukkan selisih antara pemakaian beban listrik antara hari biasa dengan hari libur. Selisih yang diperoleh ternyata lebih besar dari nol, sehingga disimpulkan bahwa pemakaian beban listrik pada hari biasa lebih tinggi dibanding pada hari libur. Selisih pemakaian beban listrik relatif tinggi terjadi pada pukul 08.00 hingga 18.00. Hal ini karena pada hari biasa terutama hari kerja, antara jam 08.00 hingga 18.00 digunakan masyarakat baik pelajar, pekerja, maupun ibu rumah tangga untuk melakukan berbagai kegiatan sehari-hari.




Gambar 4.2 Pemakaian Beban Listrik Per Hari pada (a) Hari Biasa , (b) Hari Libur Nasional, dan (c) Selisih antara Hari Biasa dengan Hari Libur.



Gambar 4.2 Pemakaian Beban Listrik Per Hari pada (a) Hari Biasa , (b) Hari Libur Nasional, dan (c) Selisih antara Hari Biasa dengan Hari Libur (Lanjutan).



Gambar 4.3 Pemakaian Beban Listrik Per Hari pada (a) Hari Biasa , (b) Bulan Puasa, dan (c) Selisih antara Hari Biasa dan Bulan Puasa.



Gambar 4.3 Pemakaian Beban Listrik Per Hari pada (a) Hari Biasa , (b) Bulan Puasa, dan (c) Selisih antara Hari Biasa dan Bulan Puasa (Lanjutan).

Selain dipengaruhi oleh hari libur nasional dan akhir pekan, konsumsi listrik juga dipengaruhi oleh bulan puasa. Berdasarkan Gambar 4.3 dapat diketahui bahwa secara umum konsumsi listrik pada bulan puasa lebih rendah dibanding dengan konsumsi listrik pada hari biasa. Keadaan ini disebabkan karena pengurangan jam kerja di kantor, instansi pemerintah dan sekolah-sekolah serta cenderung berkurangnya aktifitas masyarakat di bulan puasa sehingga penggunaan listrik menurun.

Perbandingan konsumsi listrik antara hari biasa dan bulan puasa yang disajikan pada Gambar 4.3 (a) dan (b) menunjukkan beberapa perbedaan, perbedaan ini dapat dilihat jelas pada Gambar 4.3 (c) yang menunjukkan selisih penggunaan pemakaian beban listrik antara hari biasa dengan bulan puasa. Perbedaan yang terjadi diantaranya yaitu perbedaan jam saat peningkatan pemakaian listrik di pagi hari. Pada hari biasa peningkatan pemakaian beban listrik di pagi hari dimulai pukul 5.00, dimana sebagian besar masyarakat memulai aktifitas untuk menyiapkan sarapan, bersiap-siap sekolah dan kerja serta bersiap-siap untuk memulai kegiatan lainnya. Sedangkan pada bulan puasa, kenaikan konsumsi listrik di pagi hari dimulai pukul 03.00 karena mayoritas masyarakat di Jawa Timur yang beragama Islam sedang bersiap-siap untuk melaksanakan sahur. Selain itu, perbedaan juga terjadi pada pukul 18.30 hingga 20.00, dimana pada bulan puasa konsumsi listrik pada jam tersebut cenderung lebih rendah karena masyarakat yang beragama Islam sedang menjalankan ibadah shalat tarawih di masjid. Sehingga aktifitas di rumah dalam hal penggunaan alat elektronik menjadi berkurang. Setelah pukul 20.00 pemakaian listrik kembali meningkat dan perlahan turun seiring bertambahnya malam.

4.2 Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode *Time Series Regression* dan *Double Seasonal ARIMA*

Pada sub bab ini menjelaskan mengenai peramalan pemakaian beban listrik di Jawa Timur pada bulan September 2015 hingga September 2016 menggunakan metode *Double Seasonal ARIMA* dan *Time Series Regression* tanpa menggunakan proses pemilihan input dengan *Random Forest*. Pembahasan mengenai peramalan pemakaian beban listrik di Jawa Timur yang menggunakan proses pemilihan input dengan *Random Forest* akan dibahas pada sub bab 4.3.

Langkah awal dalam menentukan model peramalan pemakaian beban listrik yaitu dengan membagi data menjadi data *in-sample* dan *out-sample*. Data *in-sample* yang digunakan yaitu data pada tanggal 24 September 2015-23 September 2016 dengan pengamatan sebanyak 17568. Sedangkan data *out-sample* sebanyak 336 pengamatan mulai tanggal 24 September 2016 hingga 30 September 2016. Berikut penjelasan langkah-langkah pembentukan model peramalan pemakaian beban listrik di Jawa Timur.

4.2.1 Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode *Time Series Regression*

Peramalan pemakaian beban listrik menggunakan *Time Series Regression* dilakukan dengan meregresikan antara pemakaian beban listrik yang merupakan variabel respon terhadap variabel prediktor yang berupa *dummy trend*, jam, hari, serta interaksi antara jam dan hari. Model yang dibentuk pada analisis ini merupakan model *Time Series Regression* yang tidak memperhatikan pengujian parameter dan asumsi residual. Persamaan model yang terbentuk yaitu sebagai berikut, dengan catatan bahwa terdapat tiga variabel *dummy* yang dihilangkan dalam pemodelan menggunakan *software* MINITAB yaitu *dummy* hari Minggu (H7), *dummy* hari Sabtu jam 24.00 (S48), dan *dummy* hari Minggu jam 24.00 (M48). Ketiga variabel tersebut

dihilangkan karena memiliki korelasi yang tinggi terhadap variabel prediktor yang lain.

$$\begin{aligned}
 Y_t = & 0,00227 \, t + 3456 \, D_{1,t} + 3415 \, D_{2,t} + 3375 \, D_{3,t} + 3338 \, D_{4,t} + 3308 \, D_{5,t} \\
 & + 3289 \, D_{6,t} + 3301 \, D_{7,t} + 3355 \, D_{8,t} + 3454 \, D_{9,t} + 3543 \, D_{10,t} + 3507 \\
 & D_{11,t} + 3373 \, D_{12,t} + 3265 \, D_{13,t} + 3250 \, D_{14,t} + 3431 \, D_{15,t} + 3587 \, D_{16,t} \\
 & + 3757 \, D_{17,t} + 3828 \, D_{18,t} + 3888 \, D_{19,t} + 3952 \, D_{20,t} + 3996 \, D_{21,t} + 4015 \\
 & D_{22,t} + 3964 \, D_{23,t} + 3824 \, D_{24,t} + 3827 \, D_{25,t} + 3959 \, D_{26,t} + 4090 \, D_{27,t} \\
 & + 4080 \, D_{28,t} + 4051 \, D_{29,t} + 4010 \, D_{30,t} + 4002 \, D_{31,t} + 3957 \, D_{32,t} + 3955 \\
 & D_{33,t} + 4029 \, D_{34,t} + 4316 \, D_{35,t} + 4474 \, D_{36,t} + 4487 \, D_{37,t} + 4460 \, D_{38,t} \\
 & + 4457 \, D_{39,t} + 4427 \, D_{40,t} + 4357 \, D_{41,t} + 4236 \, D_{42,t} + 4063 \, D_{43,t} + 3912 \\
 & D_{44,t} + 3851 \, D_{45,t} + 3739 \, D_{46,t} + 3656 \, D_{47,t} + 3579 \, D_{48,t} + 250 \, H_{1,t} \\
 & + 378 \, H_{2,t} + 344 \, H_{3,t} + 348 \, H_{4,t} + 340 \, H_{5,t} + 133 \, H_{6,t} - 27,0 \, J_{1,t} - 168 \\
 & J_{2,t} - 222 \, J_{3,t} - 192 \, J_{4,t} - 88,3 \, J_{5,t} + 232 \, S_{1,t} + 238 \, S_{2,t} + 238 \, S_{3,t} + 236 \\
 & S_{4,t} + 243 \, S_{5,t} + 227 \, S_{6,t} + 221 \, S_{7,t} + 217 \, S_{8,t} + 213 \, S_{9,t} + 198 \, S_{10,t} + 184 \\
 & S_{11,t} + 169 \, S_{12,t} + 129 \, S_{13,t} + 85,9 \, S_{14,t} + 21,5 \, S_{15,t} - 29,5 \, S_{16,t} - 63,9 \\
 & S_{17,t} - 69,9 \, S_{18,t} - 82,0 \, S_{19,t} - 84,5 \, S_{20,t} - 81,3 \, S_{21,t} - 82,9 \, S_{22,t} - 53,8 \\
 & S_{23,t} - 16,4 \, S_{24,t} - 46,8 \, S_{25,t} - 141 \, S_{26,t} - 210 \, S_{27,t} - 230 \, S_{28,t} - 237 \, S_{29,t} \\
 & - 240 \, S_{30,t} - 245 \, S_{31,t} - 213 \, S_{32,t} - 168 \, S_{33,t} - 123 \, S_{34,t} - 69,8 \, S_{35,t} - 28,9 \\
 & S_{36,t} - 16,3 \, S_{37,t} - 18,9 \, S_{38,t} - 41,9 \, S_{39,t} - 44,8 \, S_{40,t} - 31,1 \, S_{41,t} - 23,2 \\
 & S_{42,t} - 9,6 \, S_{43,t} - 19,5 \, S_{44,t} - 27,4 \, S_{45,t} - 11,1 \, S_{46,t} - 7,1 \, S_{47,t} + 192 \, M_{1,t} \\
 & + 188 \, M_{2,t} + 182 \, M_{3,t} + 183 \, M_{4,t} + 178 \, M_{5,t} + 182 \, M_{6,t} + 166 \, M_{7,t} \\
 & + 155 \, M_{8,t} + 114 \, M_{9,t} + 69,2 \, M_{10,t} + 40,1 \, M_{11,t} + 28,8 \, M_{12,t} + 35,6 \\
 & M_{13,t} - 21,5 \, M_{14,t} - 193 \, M_{15,t} - 328 \, M_{16,t} - 461 \, M_{17,t} - 516 \, M_{18,t} - 546 \\
 & M_{19,t} - 574 \, M_{20,t} - 587 \, M_{21,t} - 596 \, M_{22,t} - 552 \, M_{23,t} - 436 \, M_{24,t} - 438 \\
 & M_{25,t} - 555 \, M_{26,t} - 655 \, M_{27,t} - 656 \, M_{28,t} - 635 \, M_{29,t} - 596 \, M_{30,t} - 552 \\
 & M_{31,t} - 464 \, M_{32,t} - 384 \, M_{33,t} - 298 \, M_{34,t} - 211 \, M_{35,t} - 145 \, M_{36,t} - 117 \\
 & M_{37,t} - 105 \, M_{38,t} - 104 \, M_{39,t} - 91,8 \, M_{40,t} - 72,2 \, M_{41,t} - 59,3 \, M_{42,t} \\
 & - 50,1 \, M_{43,t} - 46,8 \, M_{44,t} - 48,2 \, M_{45,t} - 22,1 \, M_{46,t} - 18,1 \, M_{47,t} + \varepsilon_t
 \end{aligned}$$


Setelah model terbentuk kemudian dilakukan pengujian parameter secara serentak dengan taraf signifikansi sebesar 5%. Berdasarkan hasil pengujian yang ditampilkan pada Tabel 4.3 diperoleh hasil nilai *p-value* sebesar 0,000 yang berarti minimal terdapat satu parameter yang berpengaruh terhadap model. Lalu dilanjutkan dengan pengujian secara parsial pada taraf signifikansi 5% untuk mengetahui parameter yang signifikan.

Tabel 4.3 Pengujian Serentak Model 1 *Time Series Regresion*.

Sumber	db	JK	KT	F	<i>p-value</i>
Regresi	154	293617000000	1906602221	24179,68	0,000
Galat	17414	1373118493	78851		
Total	17568	294990000000			

Hasil pengujian secara parsial pada Lampiran 1 menunjukkan bahwa terdapat 43 variabel yang tidak signifikan terhadap penggunaan beban listrik di Jawa Timur. Berdasarkan Lampiran 1, variabel *trend* berpengaruh signifikan terhadap pemakaian beban listrik. Hal ini berarti bahwa secara umum pemakaian beban listrik di Jawa Timur pada tanggal 24 September 2015 hingga 23 September 2016 mengalami peningkatan. Variabel *dummy* jam seluruhnya berpengaruh signifikan terhadap pemakaian beban listrik.


Selain itu, pemakaian beban listrik di Jawa Timur juga dipengaruhi oleh interaksi antara jam dan hari. Pada hari Jumat pukul 11.30 ($J_{2,t}$), pukul 12.00 ($J_{3,t}$), pukul 12.30 ($J_{4,t}$) dan pukul 13.00 ($J_{5,t}$) berpengaruh signifikan terhadap pemakaian beban listrik. Ini berarti bahwa pada hari Jumat yang notabene masyarakat di Jawa Timur menunaikan solat Jumat mempengaruhi penggunaan pemakaian beban listrik dengan kecenderungan menurunnya pemakaian beban listrik. Variabel *dummy* pada hari Sabtu jam 0.30 (S_1) hingga jam 6.30 (S_{13}) dan jam 13.00 (S_{26}) hingga jam 17.00 (S_{34}) serta hari Minggu jam 0.30 (M_1) hingga jam 4.00 (M_8) dan jam 7.30 (M_{15}) hingga jam 18.00 (M_{36}) berpengaruh signifikan terhadap penggunaan beban listrik di Jawa Timur. Karena pada model ini tidak memperhatikan signifikansi parameter, maka parameter yang tidak signifikan tidak direduksi.




Gambar 4.4 Plot ACF Residual Model *Time Series Regression*.

Kemudian dilakukan pengujian asumsi residual yaitu *white noise* dan distribusi normal. Berdasarkan plot ACF dari residual yang disajikan pada Gambar 4.4 diketahui bahwa masih banyak lag yang melebihi batas limit sehingga secara grafis disimpulkan bahwa residual model *Time Series Rereession* belum memenuhi asumsi *white noise*. Pengujian distribusi normal untuk residual menggunakan uji Kolmogorov-Smirnov. Dari hasil pengujian tersebut yang disajikan pada Lampiran 2 diperoleh nilai $p\text{-value} < 0,010$ sehingga tolak H_0 pada taraf signifikansi 5% yang berarti bahwa residual model tersebut tidak berdistribusi normal. Hasil peramalan dengan model tersebut menghasilkan nilai RMSE sebesar 156,7925 dengan plot perbandingan antara data aktual dengan hasil ramalan disajikan pada Gambar 4.5.

Hasil ramalan pada Gambar 4.5 secara umum dapat dikatakan sudah bagus karena sudah mendekati data aktual. Tetapi jika dilihat plot perbandingan antara hasil ramalan dan data aktual pada *in-sample* ternyata model *Time Series Regression* tersebut belum bisa menangkap pola pemakaian beban listrik pada bulan puasa dan lebaran. Dari Gambar 4.6 terlihat bahwa error yang dihasilkan cukup besar pada saat bulan puasa dan lebaran. Error yang besar ini terjadi karena pada pemodelan *Time Series Regression* di atas belum memuat variabel *dummy* yang berupa variasi kalender. Oleh karena itu dilakukan pemodelan dengan menambahkan efek variasi kalender, dengan harapan dapat memperbaiki hasil peramalan.




Gambar 4.5 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression*.




Gambar 4.6 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression* pada Bulan Puasa dan Lebaran.

Variabel yang memuat efek variasi kalender meliputi variabel *dummy* bulan puasa (P_t) dan hari raya Idul Fitri ($I_{t-3}, I_{t-2}, I_{t-1}, I_t, I_{t+1}, I_{t+2}, I_{t+3}$). Berdasarkan model yang terbentuk pada Lampiran 3 diperoleh hasil pengujian secara serentak yang menunjukkan bahwa minimal terdapat satu variabel signifikan

terhadap model. Kemudian dilanjutkan pengujian secara parsial dimana terdapat 126 variabel yang berpengaruh signifikan terhadap model. Residual yang terbentuk belum memenuhi asumsi distribusi normal karena nilai p -value kurang dari 0,05 dan tidak *wihite noise* karena pada plot ACF residual masih terdapat lag yang keluar dari batas limit sesuai hasil pada Lampiran 4. Perbandingan data aktual dan hasil ramalannya disajikan pada Gambar 4.7 berikut, dengan nilai RMSE sebesar 115,185. Selain itu, pada Gambar 4.8 ditampilkan perbandingan data aktual dan peramalan untuk data *in-sample*. Dari gambar tersebut diketahui bahwa hasil ramalan untuk bulan puasa dan lebaran sudah mendekati data aktual. Hasil ramalan ini lebih baik dibandingkan dengan hasil ramalan tanpa menggunakan efek variasi kalender yang disajikan pada Gambar 4.6.



Gambar 4.7 Perbandingan Data Aktual dan Peramalan Model *Time Series Regression* dengan Variasi Kalender.



Gambar 4.8 Perbandingan Data Aktual dan Peramalan Model *Time Series Regression* dengan Variasi Kalender pada Data *In-Sample*.


Hasil peramalan model *Time Series Regression* dengan menambahkan efek variasi kalender ternyata belum menangkap pola hari libur nasional. Hal ini diketahui berdasarkan hasil ramalan yang masih berbeda jauh dari data aktual pada saat hari libur nasional. Oleh karena itu dilakukan pemodelan kembali menggunakan *Time Series Regression* dengan menambahkan efek variasi kalender dan juga *dummy* hari libur nasional. Terdapat 12 hari libur nasional yang jatuh pada hari selain hari Minggu mulai tanggal 24 September 2015 hingga 23 September 2016. Daftar hari libur nasional tertera pada Tabel 4.4.

Model *Time Series Regression* dengan menambahkan efek variasi kalender dan juga *dummy* hari libur nasional terlampir pada Lampiran 5. Berdasarkan hasil tersebut, kemudian dilakukan pengujian signifikansi parameter secara serentak dan diperoleh hasil bahwa minimal terdapat satu variabel yang signifikan terhadap model. Pengujian dilanjutkan secara parsial dimana terdapat 142 variabel yang berpengaruh signifikan terhadap model. Residual yang terbentuk belum memenuhi asumsi distribusi normal karena nilai *p-value* kurang dari 0,05 dan tidak *white noise* karena pada plot ACF residual masih terdapat lag yang keluar dari batas limit sesuai hasil pada Lampiran 6. Perbandingan data aktual dan hasil ramalannya disajikan pada Gambar 4.9, dengan nilai


RMSE sebesar 105,529. Selain itu, pada Gambar 4.10 ditampilkan perbandingan data aktual dan peramalan untuk data *in-sample*. Dari gambar tersebut diketahui bahwa hasil ramalan dengan menambahkan efek variasi kalender dan hari libur nasional lebih baik dibanding hasil ramalan pada Gambar 4.8 yang hanya menambahkan efek variasi kalender.

Tabel 4.4 Daftar Hari Libur Nasional Mulai 24 September 2015 Hingga 23 September 2016.

Variabel	Hari	Tanggal	Keterangan
$N_{1,t}$	Kamis	24 September 2015	Idul Adha 1436 H
$N_{2,t}$	Rabu	14 Oktober 2015	Tahun baru Hijriah 1437 H
$N_{3,t}$	Kamis	24 Desember 2015	Maulid Nabi Muhammad SAW
$N_{4,t}$	Jumat	25 Desember 2015	Hari raya Natal
$N_{5,t}$	Jumat	1 Januari 2016	Tahun baru Masehi
$N_{6,t}$	Senin	8 Februari 2016	Tahun baru Imlek 2567
$N_{7,t}$	Rabu	9 Maret 2016	Hari raya Nyepi
$N_{8,t}$	Jumat	25 Maret 2016	Wafat Yesus Kristus
$N_{9,t}$	Kamis	5 Mei 2016	Kenaikan Yesus Kristus
$N_{10,t}$	Jumat	6 Mei 2016	Isra Mi'raj
$N_{11,t}$	Rabu	17 Agustus 2016	Hari kemerdekaan RI
$N_{12,t}$	Senin	12 September 2016	Idul Adha 1437 H




Gambar 4.9 Perbandingan Data Aktual dan Peramalan Model *Time Series Regression* dengan Variasi Kalender dan Hari Libur Nasional.



Gambar 4.10 Perbandingan Data Aktual dan Peramalan Model *Time Series Regression* dengan Variasi Kalender dan Hari Libur Nasional pada Data *In-Sample*.


Selain memodelkan pemakaian beban listrik menggunakan data 1 tahun, pada analisis ini juga dilakukan pemodelan menggunakan data selama 1 bulan yaitu tanggal 25 Agustus 2016 hingga 23 September 2016. Karena data yang digunakan pada peramalan pemakaian beban listrik dengan proses pemilihan input baik menggunakan *Random Forest* maupun *Stepwise* menggunakan data 1 bulan. Analisis secara terperinci mengapa menggunakan data 1 bulan akan dibahas pada sub bab 4.3. Pemodelan pemakaian beban listrik selama 1 bulan menggunakan 157 variabel *dummy* seperti yang tertera pada Tabel 3.1. Model yang terbentuk terlampir pada Lampiran 7, dari model tersebut dilakukan pengujian estimasi parameter secara serentak dan diperoleh hasil bahwa minimum terdapat satu variabel yang berpengaruh signifikan terhadap model. Pengujian dilanjutkan secara parsial dimana terdapat 86 variabel yang berpengaruh signifikan terhadap model. Residual yang terbentuk belum memenuhi asumsi distribusi normal karena nilai *p-value* kurang dari 0,05 dan tidak *white noise* karena pada plot ACF residual masih terdapat lag yang keluar dari batas limit sesuai hasil pada Lampiran 8. Perbandingan data aktual dan hasil ramalannya disajikan pada Gambar 4.11, dengan nilai RMSE sebesar 144,3417.




Gambar 4.11 Perbandingan Data Aktual dan Peramalan Model *Time Series Regression* Data 1 Bulan.

4.2.2 Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode *Double Seasonal ARIMA*


Tahap awal untuk meramalkan pemakaian beban listrik di Jawa Timur berdasarkan prosedur Box-Jenkins yaitu dengan mengidentifikasi model dari data yang telah stasioner baik dalam *mean* maupun *varians*. Stasioneritas data salah satunya dapat dilihat berdasarkan *time series* plot pada Gambar 4.12. Dari gambar tersebut terlihat bahwa data belum stasioner karena terjadi fluktuasi pemakaian beban listrik. Hal ini juga didukung berdasarkan *Box-plot* pada Gambar 4.13 yang menunjukkan banyaknya pemakaian beban listrik yang tidak sama setiap jamnya. Selain itu kestasioneran data dapat diketahui berdasarkan pola ACF dan PACF. Pola ACF pada Gambar 4.14 menunjukkan adanya puncak pada lag 48, 96, 144, ... yang mengindikasikan periode musiman harian, dan puncak pada lag 336, 672, 1008, ... yang menyatakan periode musiman mingguan. Pola PACF berdasarkan Gambar 4.15 menunjukkan pola yang turun lambat menuju nol. Sehingga berdasarkan identifikasi stasioneritas data di atas dapat disimpulkan bahwa data belum stasioner.




Gambar 4.12 Time Series Plot Pemakaian Beban Listrik Tanggal 24 September 2015 - 23 September 2016.



Gambar 4.13 Box-plot Pemakaian Beban Listrik Tanggal 24 September 2015 - 23 September 2016.




Gambar 4.14 ACF Plot Pemakaian Beban Listrik Tanggal 24 September 2015 - 23 September 2016.




Gambar 4.15 PACF Plot Pemakaian Beban Listrik Tanggal 24 September 2015 - 23 September 2016.

Proses *differencing* sebanyak tiga kali yaitu lag 1, 48, dan 336 dilakukan untuk membuat data menjadi stasioner. Gambar 4.16 dan 4.17 secara berturut-turut menunjukkan plot ACF dan PACF dari data yang telah dilakukan *differencing* pada lag 1, 48, dan 336. Berdasarkan gambar tersebut dapat diketahui bahwa data telah stasioner dalam *mean* dan *varians*. Selain secara visual berdasarkan plot ACF dan PACF, kestasioneran data dapat dicek melalui plot Box-Cox untuk kestasioneran data dalam *varians* dan uji Dickey Fuller untuk kestasioneran data dalam *mean*.


Hasil plot Box-Cox pada Gambar 4.18 menunjukkan bahwa *rounded value* bernilai 1 sehingga data telah stasioner dalam varians. Sedangkan uji stasioneritas data dalam *mean* menggunakan uji Dickey Fuller, diperoleh nilai *p-value* sebesar 0,01 seperti yang ditunjukkan pada Lampiran 9. Jadi disimpulkan bahwa data telah stasioner dalam *mean*.



Gambar 4.16 ACF Plot Data *Differencing* lag 1, 48, dan 336.



Gambar 4.17 PACF Plot Data *Differencing* lag 1, 48, dan 336.



Gambar 4.18 Plot Box-Cox Data Differencing lag 1, 48, dan 336.

Setelah data stasioner kemudian dilakukan pendugaan model menggunakan plot ACF dan PACF pada Gambar 4.16 dan 4.17. Terdapat dua dugaan model *Double Seasonal* ARIMA yang diperoleh, model 1 yaitu ARIMA $(0,1,1)(0,1,1)^{48}(0,1,1)^{336}$ dan model 2 yaitu ARIMA $([1,2,4,5,7,10,16,18,20,21,27,30,41,43], 1,1)([47],1,1)^{48}(0,1,1)^{336}$. Setelah itu dilakukan estimasi dan pengujian parameter model dugaan yang ditunjukkan pada Tabel 4.5. Pada taraf kepercayaan 95% ($\alpha = 0,05$) terdapat satu parameter yang tidak signifikan pada model 1 karena nilai *p-value* kurang dari 0,05. Sedangkan pada model 2, keseluruhan parameter yang digunakan dalam model telah signifikan.

Tabel 4.5 Estimasi dan Pengujian Signifikansi Parameter Dugaan Model *Double Seasonal* ARIMA.

Model	Parameter	<i>t-value</i>	<i>p-value</i>
Model 1	$\theta_1 = -0,00304$	-0,40	0,6919
	$\Theta_{48} = 0,67654$	118,17	< 0,0001
	$\Theta_{336} = 0,80128$	170,51	< 0,0001

Tabel 4.5 Estimasi dan Pengujian Signifikansi Parameter Dugaan Model *Double Seasonal* ARIMA (Lanjutan).

Model	Parameter	<i>t-value</i>	<i>p-value</i>
Model 2	$\phi_1 = 0,56445$	11,51	< 0,0001
	$\phi_2 = 0,02081$	2,62	0,0089
	$\phi_4 = -0,02703$	-3,38	0,0007
	$\phi_5 = 0,01975$	2,47	0,0134
	$\phi_7 = -0,03405$	-5,05	< 0,0001
	$\phi_{10} = 0,04680$	7,40	< 0,0001
	$\phi_{16} = -0,04016$	-6,12	< 0,0001
	$\phi_{18} = -0,03094$	-4,09	< 0,0001
	$\phi_{20} = -0,05825$	-7,02	< 0,0001
	$\phi_{21} = -0,02231$	-2,31	0,0209
	$\phi_{27} = -0,02641$	-3,96	< 0,0001
	$\phi_{30} = 0,01501$	2,36	0,0184
	$\phi_{41} = -0,03481$	-5,25	< 0,0001
	$\phi_{43} = -0,01515$	-2,18	0,0296
	$\Phi_{47} = 0,08326$	10,78	< 0,0001
	$\theta_1 = 0,57420$	11,74	< 0,0001
	$\Theta_{48} = 0,69780$	124,00	< 0,0001
	$\Theta_{336} = 0,80572$	172,71	< 0,0001

Setelah dilakukan estimasi dan pengujian signifikansi parameter, selanjutnya menguji kesesuaian model berdasarkan residual model yang terbentuk. Pengujian residual terdiri dari pengujian *white noise* menggunakan uji Ljung-Box-Pierce dan pengujian distribusi normal menggunakan uji Kolmogorov-Smirnov. Hasil uji Ljung-Box-Pierce ditampilkan pada Tabel 4.6 yang menunjukkan bahwa pada model 1 dan 2 residualnya belum

white noise karena nilai *p-value* kurang dari $\alpha = 0,05$. Namun, berdasarkan plot ACF residual dari model 2 yang disajikan pada Gambar 4.19 telah menunjukkan bahwa residual tersebut memenuhi asumsi *white noise* karena sudah tidak terdapat lag yang signifikan hingga lag ke-48.


Tabel 4.6 Uji Asumsi Residual *White Noise* pada Dugaan Model *Double Seasonal* ARIMA.

Model	Hingga Lag	<i>Chi-Square</i>	<i>df</i>	<i>p-value</i>
Model 1	6	39,18	3	<0,0001
	12	110,23	9	<0,0001
	18	184,02	15	<0,0001
	24	384,92	21	<0,0001
	30	414,60	27	<0,0001
	36	425,68	33	<0,0001
	42	444,20	39	<0,0001
	48	604,14	45	<0,0001
Model 2	6	.	0	.
	12	.	0	.
	18	.	0	.
	24	22,53	6	0,0010
	30	28,67	12	0,0044
	36	33,21	18	0,0157
	42	41,74	24	0,0138
	48	48,80	30	0,0165


Pengujian distribusi normal menggunakan uji Kolmogorov-Smirnov yang disajikan pada Tabel 4.7 yang menunjukkan bahwa residual kedua model tidak memenuhi asumsi distribusi normal berdasarkan nilai *p-value* yang kurang dari 0,05. Hal ini disebabkan karena data pemakaian beban listrik di Jawa Timur memiliki banyak *outlier* seperti yang ditunjukkan pada Gambar 4.20.

Tabel 4.7 Uji Asumsi Residual Distribusi Normal pada Dugaan Model *Double Seasonal* ARIMA.

Model	Kolmogorov-Smirnov	<i>p-value</i>
Model 1	0,064	<0,010
Model 2	0,057	<0,010



Gambar 4.19 ACF Residual Model 2 *Double Seasonal ARIMA*.



Gambar 4.20 Box- Plot Data *Differencing* lag 1, 48, dan 336.

Berdasarkan uraian di atas mulai dari stasioneritas data hingga pengujian asumsi residual, diperoleh hasil bahwa model 1 terdapat parameter yang tidak signifikan, residual tidak *white noise* dan tidak berdistribusi normal. Sedangkan pada model 2 seluruh parameter telah signifikan, residual *white noise* tetapi tidak berdistribusi normal.


Pemilihan model terbaik menggunakan kriteria *out-sample* dengan nilai RMSE. Berdasarkan Tabel 4.8 diketahui bahwa nilai RMSE model 2 lebih kecil dibanding model 1. Selain itu,

perbandingan antara data aktual dengan ramalan model 1 dan 2 juga dapat diketahui secara grafis berdasarkan *time series* plot pada Gambar 4.21. Gambar tersebut menunjukkan bahwa hasil ramalan model 2 lebih mendekati nilai aktual dibanding model 1. Jadi, model *Double Seasonal* ARIMA yang melibatkan banyak lag menghasilkan ramalan yang lebih baik dibandingkan model yang sederhana. Sehingga pada peramalan pemakaian beban listrik di Jawa Timur dengan metode *Double Seasonal* ARIMA menggunakan model 2 dengan persamaan sebagai berikut.

$$\begin{aligned}
 &(1 - 0,56445B - 0,02081B^2 - 0,02703B^4 - 0,01975B^5 + 0,03405B^7 \\
 &- 0,0468B^{10} + 0,04016B^{16} + 0,03094B^8 + 0,05825B^{20} + 0,02231B^{21} \\
 &+ 0,02641B^{27} - 0,01501B^{30} + 0,03481B^{41} + 0,01515B^{43}) \\
 &(1 - 0,08326B^{47})(1 - B)(1 - B^{48})(1 - B^{336})Y_t = \\
 &(1 - 0,5742B)(1 - 0,6978B^{48})(1 - 0,80572B^{336})a_t
 \end{aligned}$$


Tabel 4.8 Nilai RMSE pada Dugaan Model *Double Seasonal* ARIMA.

Model	RMSE
Model 1	189,500
Model 2	156,579




Gambar 4.21 Perbandingan Data Aktual dengan Peramalan Model *Double Seasonal* ARIMA.

Pada model *Double Seasonal ARIMA* ini juga dilakukan pemodelan menggunakan data 1 bulan mulai tanggal 25 Agustus 2015 hingga 23 September 2016. Langkah awal dilakukan dengan mengecek stasioneritas data. Data telah stasioner dalam *mean* maupun *varians* setelah dilakukan *differencing* sebanyak 3 kali yaitu lag 1, 48, dan 336. Pada Gambar 4.22 dan 4.23 ditampilkan plot ACF dan PACF dari data yang telah di *differencing*.



Gambar 4.22 ACF Data 1 Bulan yang di *Differencing* pada Lag 1, 48, dan 336.



Gambar 4.23 PACF Data 1 Bulan yang di *Differencing* pada Lag 1, 48, dan 336.

Berdasarkan plot ACF dan PACF tersebut maka model yang diduga yaitu ARIMA ([5,6,11,20,24,30,42],1,1)(0,1,1)⁴⁸(0,1,1)³³⁶. Setelah itu dilakukan estimasi dan pengujian parameter model dugaan yang ditunjukkan pada Tabel 4.9. Pada taraf kepercayaan 95% ($\alpha=0,05$), keseluruhan parameter yang digunakan dalam model telah signifikan.


Tabel 4.9 Estimasi dan Pengujian Signifikansi Parameter Dugaan Model *Double Seasonal* ARIMA Data 1 Bulan.

Parameter	<i>t-value</i>	<i>p-value</i>
$\phi_5 = 0,06889$	2,27	0,0232
$\phi_6 = 0,07010$	2,30	0,0218
$\phi_{11} = 0,07391$	2,43	0,0153
$\phi_{20} = -0,12768$	-4,19	<0,0001
$\phi_{24} = 0,06310$	2,07	0,0390
$\phi_{30} = 0,07668$	2,51	0,0121
$\phi_{42} = -0,09072$	-2,97	0,0031
$\theta_1 = 0,09273$	3,00	0,0028
$\Theta_{48} = 0,68026$	28,92	< 0,0001
$\Theta_{336} = 0,56151$	17,36	< 0,0001

Setelah dilakukan estimasi dan pengujian signifikansi parameter, selanjutnya menguji kesesuaian model berdasarkan residual model yang terbentuk. Pengujian residual terdiri dari pengujian *white noise* menggunakan uji Ljung-Box-Pierce dan pengujian distribusi normal menggunakan uji Kolmogorov-Smirnov. Hasil uji Ljung-Box-Pierce ditampilkan pada Tabel 4.10 yang menunjukkan bahwa hingga lag 12 model belum *white noise* karena nilai *p-value* kurang dari $\alpha=0,05$. Namun, berdasarkan plot ACF residual dari yang disajikan pada Gambar 4.24 telah menunjukkan bahwa residual tersebut memenuhi asumsi *white noise* karena sudah tidak terdapat lag yang signifikan hingga lag ke-48.

Tabel 4.10 Uji Asumsi Residual *White Noise* pada Dugaan Model *Double Seasonal* ARIMA Data 1 Bulan.


Hingga Lag	Chi-Square	df	p-value
6	.	0	.
12	7,10	2	0,0288
18	12,34	8	0,1366
24	26,08	14	0,0253
30	30,35	20	0,0644
36	36,56	26	0,0819
42	44,00	32	0,0768
48	50,72	38	0,0812




Gambar 4.24 ACF Residual Model *Double Seasonal* ARIMA Data 1 Bulan.

Pengujian distribusi normal menggunakan uji Kolmogorov-Smirnov yang disajikan pada Gambar 4.25 yang menunjukkan bahwa residual kedua model tidak memenuhi asumsi distribusi normal berdasarkan nilai *p-value* yang kurang dari 0,05. Hal ini disebabkan karena data pemakaian beban listrik di Jawa Timur memiliki banyak *outlier*. Berdasarkan hasil peramalan tersebut, diperoleh nilai RMSE sebesar 251,5624 dengan plot perbandingan antara data aktual dengan hasil peramalan disajikan pada Gambar 4.26. Persamaan model yang terbentuk dari pemodelan data 1 bulan yaitu sebagai berikut.

$$(1 + 0,06889B^5 + 0,07010B^6 + 0,07391B^{11} - 0,12768B^{20} + 0,06310B^{24} \\ + 0,07668B^{30} - 0,09072B^{42})(1 - B)(1 - B^{48})(1 - B^{336})Y_t = \\ (1 - 0,09273B)(1 - 0,68026B^{48})(1 - 0,56151B^{336})a_t$$



Gambar 4.25 Uji Kolmogorov-Smirnov Residual Model *Double Seasonal* ARIMA Data 1 Bulan.




Gambar 4.26 Perbandingan Data Aktual dengan Peramalan Model *Double Seasonal* ARIMA Data 1 Bulan.

4.3 Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode *Time Series Regression* dan *Double Seasonal ARIMA* dengan Pemilihan Input Menggunakan *Random Forest*

Sub bab ini menjelaskan mengenai analisis peramalan pemakaian beban listrik di Jawa Timur menggunakan metode *Double Seasonal ARIMA* dan *Time Series Regression* dengan proses pemilihan input menggunakan *Random Forest*. Metode *Random Forest* digunakan untuk memilih input baik lag maupun *dummy* yang paling berpengaruh terhadap variabel respon yang berupa pemakaian beban listrik di Jawa Timur. Metode *Random Forest* terdiri dari 3 tahapan yaitu *preliminary elimination and ranking* (tahap 1), *variabel selection for interpretation* (tahap 2), dan *variabel selection for prediction* (tahap 3). Pada tahap 1 banyaknya *forest* yang dibangkitkan sebanyak 40 *forest*, tahap 2 sebanyak 20 *forest*, dan tahap 3 sebanyak 20 *forest*. Dimana setiap *forest* terdiri dari 1000 *tree*.

Data *in-sample* yang digunakan tidak sebanyak ketika meramalkan pemakaian beban listrik tanpa menggunakan *Random Forest*. Karena ketika menggunakan data *in-sample* selama 1 tahun atau 17568 observasi, *R Software* tidak mampu melakukan *running* secara keseluruhan karena keterbatasan memori. Oleh karena itu, pada peramalan yang melibatkan proses pemilihan input dengan *Random Forest* menggunakan data *in-sample* selama 1 bulan (30 hari) atau 1440 observasi mulai tanggal 25 Agustus 2016 hingga 23 September 2016. Kemudian untuk data *out-sample* tetap sama, yaitu 336 observasi mulai tanggal 24 September 2016 hingga 30 September 2016. Namun, cara memperoleh hasil *forecast* dilakukan dengan metode *window time* karena ketika menggunakan data *in-sample* hanya 1 bulan (30 hari) tidak akan menghasilkan ramalan yang baik selama 1 minggu kedepan. Sehingga pengamatan pada hari ke-1 hingga 30 dilakukan proses pemilihan input dengan *Random Forest* kemudian hasilnya digunakan sebagai variabel prediktor dalam model *Time Series Regression* yang digunakan untuk meramalkan hari ke-31. Lalu pengamatan hari ke-2 hingga 31 digunakan untuk meramalkan hari

ke-32, begitu seterusnya hingga diperoleh nilai ramalan selama 7 hari kedepan atau sebanyak 336 observasi. Berikut pada Gambar 4.27 ditampilkan simulasi *window time* yang digunakan pada penelitian ini.



Gambar 4.27 Simulasi *Window Time*.

4.3.1 Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode *Time Series Regression* dengan Pemilihan Input Menggunakan *Random Forest*

Metode *Random Forest* terdiri dari 3 tahapan yaitu *preliminary elimination and ranking* (tahap 1), *variabel selection for interpretation* (tahap 2), dan *variabel selection for prediction* (tahap 3). Hasil pemilihan variabel *dummy* pada tahap ketiga digunakan sebagai variabel prediktor yang selanjutnya diregresikan terhadap variabel respon yang berupa pemakaian beban listrik di Jawa Timur. Pada Tabel 4.11 ditampilkan hasil variabel yang terpilih pada tahap ketiga untuk masing-masing *window* dari 157 variabel *dummy* yang diseleksi. Seluruh *window*

memberikan hasil yang sama pada tahap ketiga dengan terpilih 2 variabel yang paling berpengaruh terhadap pemakaian beban lisrik di Jawa Timur yaitu *trend* (t) dan variabel *dummy* hari Minggu ($H_{7,t}$).


Tabel 4.11 Hasil Pemilihan *Dummy* Tahap Ketiga dengan *Random Forest*.

Window	Variabel Terpilih	Keterangan
Window 1	$H_{7,t}$	Hari Minggu
	t	<i>Trend</i>
Window 2	$H_{7,t}$	Hari Minggu
	t	<i>Trend</i>
Window 3	$H_{7,t}$	Hari Minggu
	t	<i>Trend</i>
Window 4	$H_{7,t}$	Hari Minggu
	t	<i>Trend</i>
Window 5	$H_{7,t}$	Hari Minggu
	t	<i>Trend</i>
Window 6	$H_{7,t}$	Hari Minggu
	t	<i>Trend</i>
Window 7	$H_{7,t}$	Hari Minggu
	t	<i>Trend</i>

Tabel 4.12 Model *Time Series Regresion* dengan *Random Forest* pada Setiap Window

Window	Persamaan Model
Window 1	$Z_t = 855 H_{7,t} + 4,33 t + \varepsilon_t$
Window 2	$Z_t = 1082 H_{7,t} + 4,30 t + \varepsilon_t$
Window 3	$Z_t = 555 H_{7,t} + 4,29 t + \varepsilon_t$
Window 4	$Z_t = 787 H_{7,t} + 4,26 t + \varepsilon_t$
Window 5	$Z_t = 127 H_{7,t} + 4,36 t + \varepsilon_t$
Window 6	$Z_t = 397 H_{7,t} + 4,34 t + \varepsilon_t$
Window 7	$Z_t = 616 H_{7,t} + 4,33 t + \varepsilon_t$

Hasil seleksi variabel menggunakan *random Forest* untuk masing-masing *window* selanjutnya digunakan untuk menentukan model *Time Series Regression* seperti yang tertera pada Tabel 4.12. Berdasarkan model yang terbentuk, kemudian dilakukan pengujian parameter secara serentak untuk masing-masing *window* dengan taraf signifikansi sebesar 5%. Dari hasil pengujian pada Lampiran 24 - 30 terhadap ketujuh *window* diperoleh nilai *p-value* sebesar 0,000 yang berarti minimal terdapat satu parameter yang berpengaruh signifikan terhadap model. Lalu dilanjutkan dengan pengujian secara parsial pada taraf signifikansi 5% untuk mengetahui parameter yang signifikan. Ketujuh *window* menghasilkan kesimpulan yang sama yaitu variabel *trend* dan *dummy* hari Minggu berpengaruh signifikan terhadap model. Selain itu, hasil residual dari ketujuh *window* belum *white noise* karena pada plot ACF residual masih terdapat lag yang keluar dari batas limitnya. Kemudian residual model tersebut tidak berdistribusi normal berdasarkan hasil pada Lampiran 31, karena terdapat banyak data *outlier*. Berdasarkan ketujuh model dari setiap *window* yang terbentuk selanjutnya dilakukan peramalan pemakaian beban listrik dan diperoleh nilai RMSE sebesar 2374,297.



Gambar 4.28 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression* Menggunakan *Random Forest* Tahap 3.

Berdasarkan nilai RMSE dan Gambar 4.28, ramalan pemakaian beban listrik di Jawa Timur antara tanggal 24 – 30 September 2016 masih sangat jauh dari data aktual. Hal ini terjadi karena variabel yang terpilih berdasarkan hasil seleksi tahap ketiga *Random Forest* hanya menghasilkan 2 variabel yang diduga berpengaruh terhadap variabel respon. Dua variabel tersebut yaitu variabel *trend* (t) dan *dummy* hari Minggu ($H_{7,t}$) ternyata belum cukup mengcover penyebab fluktuasi pemakaian beban listrik di Jawa Timur, sehingga menghasilkan ramalan yang tidak akurat. Oleh karena itu untuk memperbaiki peramalan pemakaian beban listrik, digunakanlah hasil seleksi *Random Forest* pada tahap kedua (*Variable selection for interpretation*). Karena pada tahap tersebut menghasilkan variabel terpilih yang lebih banyak. Sehingga harapannya dapat menghasilkan peramalan yang lebih baik. Variabel yang terpilih pada tahap kedua untuk masing-masing *window* disajikan pada Tabel 4.13. Hasil seleksi variabel pada tahap kedua kemudian digunakan sebagai variabel prediktor pada model *Time Series Regression*.

Tabel 4.13 *Dummy* Terpilih pada Tahap Kedua dengan *Random Forest*.

<i>Window</i>	Banyaknya	Variabel Terseleksi
<i>Window 1</i>	60 variabel	$H_{7,t}, t, H_{1,t}, D_{36,t}, H_{6,t}, D_{37,t}, D_{38,t}, D_{39,t},$ $D_{40,t}, D_{14,t}, D_{35,t}, D_{13,t}, D_{41,t}, D_{7,t}, D_{6,t}, D_{5,t},$ $D_{8,t}, D_{4,t}, D_{3,t}, D_{12,t}, D_{15,t}, D_{2,t}, D_{42,t}, D_{9,t},$ $D_{1,t}, H_{5,t}, H_{4,t}, D_{11,t}, D_{48,t}, D_{10,t}, H_{3,t}, D_{16,t},$ $D_{47,t}, D_{27,t}, D_{43,t}, H_{2,t}, D_{28,t}, M_{36,t}, M_{37,t},$ $M_{38,t}, M_{39,t}, D_{46,t}, M_{40,t}, M_{41,t}, D_{29,t},$ $M_{35,t}, M_{42,t}, D_{24,t}, D_{45,t}, D_{44,t}, D_{25,t}, M_{43,t},$ $S_{35,t}, S_{41,t}, S_{40,t}, D_{34,t}, S_{39,t}, S_{38,t}, D_{30,t}, S_{37,t}$

Tabel 4.13 *Dummy* Terpilih pada Tahap Kedua dengan *Random Forest* (Lanjutan).

<i>Window</i>	Banyaknya	Variabel Terseleksi
<i>Window 2</i>	66 variabel	$H_{7,t}, t, H_{1,t}, H_{6,t}, D_{36,t}, D_{37,t}, D_{38,t}, D_{39,t},$ $D_{40,t}, D_{35,t}, D_{14,t}, D_{13,t}, D_{41,t}, D_{7,t}, D_{6,t},$ $D_{5,t}, D_{8,t}, D_{4,t}, D_{3,t}, D_{12,t}, H_{5,t}, D_{15,t}, D_{42,t},$ $D_{2,t}, D_{9,t}, D_{1,t}, H_{4,t}, H_{3,t}, D_{11,t}, D_{48,t},$ $D_{10,t}, D_{16,t}, D_{47,t}, H_{2,t}, D_{43,t}, D_{27,t}, D_{28,t},$ $M_{36,t}, M_{37,t}, M_{39,t}, M_{38,t}, D_{46,t}, M_{40,t},$ $M_{41,t}, D_{29,t}, M_{35,t}, M_{42,t}, D_{24,t}, S_{35,t}, S_{40,t},$ $S_{39,t}, S_{38,t}, S_{41,t}, S_{37,t}, D_{44,t}, S_{36,t}, D_{45,t},$ $M_{43,t}, D_{25,t}, D_{34,t}, S_{42,t}, S_{14,t}, D_{30,t}, S_{15,t},$ $S_{13,t}, M_{44,t},$
<i>Window 3</i>	62 variabel	$H_{7,t}, t, H_{1,t}, H_{6,t}, D_{36,t}, D_{37,t}, D_{38,t}, D_{39,t},$ $D_{40,t}, D_{35,t}, D_{14,t}, D_{13,t}, D_{41,t}, D_{7,t}, D_{6,t}, D_{5,t},$ $D_{8,t}, D_{4,t}, H_{4,t}, D_{12,t}, D_{3,t}, D_{42,t}, H_{5,t}, D_{15,t},$ $D_{2,t}, D_{9,t}, H_{3,t}, D_{1,t}, D_{11,t}, D_{48,t}, D_{10,t}, H_{2,t},$ $D_{16,t}, D_{43,t}, D_{47,t}, M_{37,t}, M_{36,t}, M_{39,t}, M_{38,t},$ $M_{40,t}, M_{41,t}, D_{27,t}, M_{35,t}, M_{42,t}, D_{46,t}, D_{28,t},$ $D_{44,t}, M_{43,t}, D_{29,t}, D_{45,t}, S_{35,t}, S_{39,t}, D_{24,t},$ $S_{38,t}, S_{40,t}, S_{41,t}, S_{37,t}, S_{36,t}, D_{34,t}, M_{44,t},$ $S_{42,t}, D_{25,t},$
<i>Window 4</i>	64 variabel	$H_{7,t}, t, H_{1,t}, H_{6,t}, D_{36,t}, D_{37,t}, D_{38,t}, D_{39,t},$ $D_{40,t}, D_{35,t}, D_{14,t}, D_{13,t}, D_{41,t}, D_{7,t}, D_{6,t}, D_{5,t},$ $D_{8,t}, D_{4,t}, H_{4,t}, H_{5,t}, D_{3,t}, D_{12,t}, D_{42,t}, D_{15,t},$ $D_{2,t}, H_{3,t}, D_{9,t}, D_{1,t}, D_{11,t}, D_{48,t}, D_{10,t}, H_{2,t},$ $D_{16,t}, D_{47,t}, D_{43,t}, M_{37,t}, M_{36,t}, M_{39,t}, M_{38,t},$ $M_{40,t}, M_{41,t}, D_{27,t}, M_{42,t}, M_{35,t}, D_{28,t}, D_{46,t},$ $D_{29,t}, M_{43,t}, D_{44,t}, D_{24,t}, D_{34,t}, D_{25,t}, S_{35,t},$ $M_{44,t}, S_{38,t}, S_{39,t}, S_{37,t}, S_{40,t}, S_{41,t}, S_{36,t},$ $D_{17,t}, M_{54,t}, D_{30,t}$

Tabel 4.13 *Dummy* Terpilih pada Tahap Kedua dengan *Random Forest* (Lanjutan).

<i>Window</i>	Banyaknya	Variabel Terseleksi
<i>Window 5</i>	60 variabel	$H_{7,t}, t, H_{1,t}, H_{6,t}, D_{36,t}, D_{37,t}, D_{38,t}, D_{39,t},$ $D_{40,t}, D_{35,t}, D_{14,t}, D_{13,t}, D_{41,t}, D_{7,t}, D_{6,t},$ $D_{5,t}, D_{8,t}, D_{4,t}, D_{3,t}, D_{12,t}, D_{2,t}, D_{15,t}, D_{42,t},$ $D_{9,t}, D_{1,t}, H_{4,t}, H_{5,t}, D_{11,t}, H_{3,t}, D_{48,t}, D_{10,t},$ $H_{2,t}, D_{16,t}, D_{47,t}, D_{43,t}, D_{27,t}, D_{28,t}, M_{37,t},$ $M_{36,t}, M_{39,t}, M_{38,t}, M_{40,t}, D_{46,t}, M_{41,t},$ $M_{42,t}, M_{35,t}, D_{29,t}, D_{24,t}, D_{45,t}, D_{44,t}, M_{43,t},$ $D_{25,t}, D_{34,t}, D_{17,t}, S_{35,t}, S_{40,t}, S_{41,t}, S_{38,t},$ $S_{39,t}, S_{37,t}$
<i>Window 6</i>	57 variabel	$H_{7,t}, t, H_{1,t}, H_{6,t}, D_{36,t}, D_{37,t}, D_{38,t}, D_{39,t},$ $D_{40,t}, D_{35,t}, D_{14,t}, D_{13,t}, D_{41,t}, D_{7,t}, D_{6,t},$ $D_{5,t}, D_{8,t}, D_{4,t}, D_{3,t}, D_{12,t}, D_{2,t}, D_{15,t}, H_{3,t},$ $D_{42,t}, D_{9,t}, H_{4,t}, D_{1,t}, H_{5,t}, D_{11,t}, D_{48,t}, H_{2,t},$ $D_{10,t}, D_{16,t}, D_{47,t}, D_{43,t}, D_{27,t}, M_{36,t}, M_{37,t},$ $M_{39,t}, M_{38,t}, D_{28,t}, M_{40,t}, D_{46,t}, M_{41,t},$ $M_{42,t}, M_{35,t}, D_{29,t}, D_{24,t}, D_{45,t}, D_{44,t}, M_{43,t},$ $D_{25,t}, D_{17,t}, S_{35,t}, D_{34,t}, S_{38,t}, S_{39,t}$
<i>Window 7</i>	55 variabel	$H_{7,t}, t, H_{1,t}, H_{6,t}, D_{36,t}, D_{37,t}, D_{38,t}, D_{39,t},$ $D_{40,t}, D_{35,t}, D_{14,t}, D_{13,t}, D_{41,t}, D_{7,t}, D_{6,t},$ $H_{4,t}, D_{5,t}, D_{8,t}, D_{4,t}, H_{3,t}, H_{5,t}, D_{12,t}, D_{3,t},$ $D_{2,t}, D_{15,t}, D_{42,t}, D_{9,t}, D_{1,t}, D_{11,t}, D_{48,t},$ $H_{2,t}, D_{10,t}, D_{16,t}, D_{47,t}, D_{43,t}, D_{27,t}, M_{36,t},$ $M_{37,t}, M_{38,t}, M_{39,t}, M_{40,t}, D_{46,t}, D_{28,t},$ $M_{41,t}, M_{42,t}, M_{35,t}, D_{29,t}, D_{24,t}, D_{45,t}, D_{44,t},$ $M_{43,t}, D_{17,t}, D_{25,t}, S_{35,t}, D_{34,t}$

Berdasarkan variabel yang terpilih pada tahap kedua (*Variabel selection for interpretation*) metode *Random Forest*, maka model yang terbentuk untuk setiap *window* yaitu sebagai berikut.

1) Model *Time Series Regression window 1*

$$\begin{aligned}
 Y_t = & 3802 H_{7,t} - 0,0089 t + 4136 H_{1,t} + 669 D_{36,t} + 4233 H_{6,t} + 658 D_{37,t} \\
 & + 621 D_{38,t} + 610 D_{39,t} + 563 D_{40,t} - 601 D_{14,t} + 526 D_{35,t} - 586 D_{13,t} \\
 & + 491 D_{41,t} - 511 D_{7,t} - 510 D_{6,t} - 480 D_{5,t} - 463 D_{8,t} - 447 D_{4,t} - 405 \\
 & D_{3,t} - 433 D_{12,t} - 454 D_{15,t} - 373 D_{2,t} + 353 D_{42,t} - 344 D_{9,t} - 327 D_{1,t} \\
 & + 4476 H_{5,t} + 4478 H_{4,t} - 276 D_{11,t} - 265 D_{48,t} - 227 D_{10,t} + 4486 H_{3,t} \\
 & - 306 D_{16,t} - 178 D_{47,t} + 162 D_{27,t} + 196 D_{43,t} + 4421 H_{2,t} + 141 D_{28,t} \\
 & + 64 M_{36,t} + 65 M_{37,t} + 69 M_{38,t} + 86 M_{39,t} - 88,0 D_{46,t} + 78 M_{40,t} \\
 & + 110 M_{41,t} + 116 D_{29,t} - 61 M_{35,t} + 154 M_{42,t} - 120 D_{24,t} + 24,0 D_{45,t} \\
 & + 83,6 D_{44,t} - 104 D_{25,t} + 172 M_{43,t} - 90 S_{35,t} - 88 S_{41,t} - 103 S_{40,t} \\
 & + 117 D_{34,t} - 94 S_{39,t} - 68 S_{38,t} + 80,6 D_{30,t} - 74 S_{37,t} + \varepsilon_t
 \end{aligned}$$

2) Model *Time Series Regression window 2*

$$\begin{aligned}
 Y_t = & 3814 H_{7,t} - 0,0366 t + 4153 H_{1,t} + 4238 H_{6,t} + 685 D_{36,t} + 662 D_{37,t} \\
 & + 622 D_{38,t} + 615 D_{39,t} + 569 D_{40,t} + 529 D_{35,t} - 610 D_{14,t} - 599 D_{13,t} \\
 & + 496 D_{41,t} - 502 D_{7,t} - 500 D_{6,t} - 469 D_{5,t} - 453 D_{8,t} - 439 D_{4,t} - 398 \\
 & D_{3,t} - 429 D_{12,t} + 4493 H_{5,t} - 451 D_{15,t} + 375 D_{42,t} - 365 D_{2,t} - 335 D_{9,t} \\
 & - 317 D_{1,t} + 4526 H_{4,t} + 4506 H_{3,t} - 271 D_{11,t} - 266 D_{48,t} - 220 D_{10,t} \\
 & - 305 D_{16,t} - 181 D_{47,t} + 4439 H_{2,t} + 191 D_{43,t} + 151 D_{27,t} + 133 D_{28,t} \\
 & + 53 M_{36,t} + 65 M_{37,t} + 85 M_{39,t} + 73 M_{38,t} - 89,9 D_{46,t} + 77 M_{40,t} \\
 & + 110 M_{41,t} + 109 D_{29,t} - 59 M_{35,t} + 137 M_{42,t} - 117 D_{24,t} - 85 S_{35,t} \\
 & - 130 S_{40,t} - 111 S_{39,t} - 78 S_{38,t} - 105 S_{41,t} - 87 S_{37,t} + 57,6 D_{44,t} - 90 \\
 & S_{36,t} + 22,3 D_{45,t} + 182 M_{43,t} - 105 D_{25,t} + 118 D_{34,t} - 128 S_{42,t} + 77 \\
 & S_{14,t} + 72,1 D_{30,t} + 5 S_{15,t} + 113 S_{13,t} + 170 M_{44,t} + \varepsilon_t
 \end{aligned}$$

3) Model *Time Series Regression window 3*

$$\begin{aligned}
Y_t = & 3812 H_{7,t} - 0,0574 t + 4159 H_{1,t} + 4251 H_{6,t} + 691 D_{36,t} \\
& + 670 D_{37,t} + 628 D_{38,t} + 622 D_{39,t} + 579 D_{40,t} + 538 D_{35,t} \\
& - 588 D_{14,t} - 570 D_{13,t} + 504 D_{41,t} - 485 D_{7,t} - 482 D_{6,t} \\
& - 452 D_{5,t} - 436 D_{8,t} - 423 D_{4,t} + 4534 H_{4,t} - 417 D_{12,t} \\
& - 381 D_{3,t} + 382 D_{42,t} + 4524 H_{5,t} - 447 D_{15,t} - 347 D_{2,t} \\
& - 321 D_{9,t} + 4513 H_{3,t} - 301 D_{1,t} - 260 D_{11,t} - 253 D_{48,t} \\
& - 209 D_{10,t} + 4445 H_{2,t} - 304 D_{16,t} + 197 D_{43,t} - 169 D_{47,t} \\
& + 65 M_{37,t} + 52 M_{36,t} + 89 M_{39,t} + 83 M_{38,t} + 73 M_{40,t} \\
& + 99 M_{41,t} + 137 D_{27,t} - 36 M_{35,t} + 124 M_{42,t} - 78,3 D_{46,t} \\
& + 121 D_{28,t} + 64,3 D_{44,t} + 166 M_{43,t} + 97,9 D_{29,t} + 33,7 D_{45,t} \\
& - 94 S_{35,t} - 116 S_{39,t} - 114 D_{24,t} - 84 S_{38,t} - 140 S_{40,t} \\
& - 112 S_{41,t} - 94 S_{37,t} - 96 S_{36,t} + 122 D_{34,t} + 158 M_{44,t} \\
& - 135 S_{42,t} - 104 D_{25,t} + \varepsilon_t
\end{aligned}$$

4) Model *Time Series Regression window 4*

$$\begin{aligned}
Y_t = & 3818 H_{7,t} - 0,0486 t + 4191 H_{1,t} + 4265 H_{6,t} + 670 D_{36,t} \\
& + 650 D_{37,t} + 609 D_{38,t} + 601 D_{39,t} + 558 D_{40,t} + 523 D_{35,t} \\
& - 611 D_{14,t} - 598 D_{13,t} + 483 D_{41,t} - 519 D_{7,t} - 514 D_{6,t} \\
& - 487 D_{5,t} - 467 D_{8,t} - 457 D_{4,t} + 4545 H_{4,t} + 4534 H_{5,t} \\
& - 414 D_3 - 448 D_{12,t} + 339 D_{42,t} - 468 D_{15,t} - 382 D_{2,t} \\
& + 4525 H_{3,t} - 352 D_{9,t} - 334 D_{1,t} - 292 D_{11,t} - 269 D_{48,t} \\
& - 240 D_{10,t} + 4457 H_{2,t} - 323 D_{16,t} - 185 D_{47,t} + 178 D_{43,t} \\
& + 70 M_{37,t} + 58 M_{36,t} + 95 M_{39,t} + 87 M_{38,t} + 79 M_{40,t} \\
& + 105 M_{41,t} + 129 D_{27,t} + 152 M_{42,t} - 36 M_{35,t} + 117 D_{28,t} \\
& - 95,0 D_{46,t} + 97,4 D_{29,t} + 170 M_{43,t} + 44,4 D_{44,t} - 12,1 D_{45,t} \\
& - 129 D_{24,t} + 115 D_{34,t} - 118 D_{25,t} - 82 S_{35,t} + 163 M_{44,t} \\
& - 80 S_{38,t} - 109 S_{39,t} - 95 S_{37,t} - 130 S_{40,t} - 105 S_{41,t} - 96 S_{36,t} \\
& - 175 D_{17,t} + 177 M_{45,t} + 59,4 D_{30,t} + \varepsilon_t
\end{aligned}$$

5) Model *Time Series Regression window 5*

$$\begin{aligned}
 Y_t = & 3835 H_{7,t} - 0,0502 t + 4205 H_{1,t} + 4278 H_{6,t} + 640 D_{36,t} \\
 & + 636 D_{37,t} + 596 D_{38,t} + 591 D_{39,t} + 545 D_{40,t} + 514 D_{35,t} \\
 & - 634 D_{14,t} - 625 D_{13,t} + 468 D_{41,t} - 552 D_{7,t} - 547 D_{6,t} \\
 & - 520 D_{5,t} - 498 D_{8,t} - 490 D_{4,t} - 446 D_{3,t} - 476 D_{12,t} \\
 & - 416 D_{2,t} - 485 D_{15,t} + 324 D_{42,t} - 381 D_{9,t} - 366 D_{1,t} \\
 & + 4560 H_{4,t} + 4549 H_{5,t} - 321 D_{11,t} + 4539 H_{3,t} - 293 D_{48,t} \\
 & - 269 D_{10,t} + 4462 H_{2,t} - 334 D_{16,t} - 209 D_{47,t} + 163 D_{43,t} \\
 & + 129 D_{27,t} + 116 D_{28,t} + 56 M_{37,t} + 60 M_{36,t} + 84 M_{39,t} \\
 & + 73 M_{38,t} + 62 M_{40,t} - 118 D_{46,t} + 90 M_{41,t} + 141 M_{42,t} \\
 & - 69 M_{35,t} + 95,9 D_{29,t} - 136 D_{24,t} - 3,6 D_{45,t} + 50,1 D_{44,t} \\
 & + 157 M_{43,t} - 128 D_{25,t} + 105 D_{34,t} - 183 D_{17,t} - 86 S_{35,t} \\
 & - 131 S_{40,t} - 103 S_{41,t} - 80 S_{38,t} - 112 S_{39,t} - 95 S_{37,t} + \varepsilon_t
 \end{aligned}$$

6) Model *Time Series Regression window 6*


$$\begin{aligned}
 Y_t = & 3802 H_{7,t} - 0,0128 t + 4118 H_{1,t} + 4240 H_{6,t} + 637 D_{36,t} \\
 & + 617 D_{37,t} + 588 D_{38,t} + 585 D_{39,t} + 521 D_{40,t} + 512 D_{35,t} \\
 & - 628 D_{14,t} - 619 D_{13,t} + 448 D_{41,t} - 543 D_{7,t} - 538 D_{6,t} \\
 & - 510 D_{5,t} - 489 D_{8,t} - 480 D_{4,t} - 437 D_{3,t} - 471 D_{12,t} \\
 & - 406 D_{2,t} - 480 D_{15,t} + 4511 H_{3,t} + 320 D_{42,t} - 372 D_{9,t} \\
 & + 4534 H_{4,t} - 356 D_{1,t} + 4521 H_{5,t} - 319 D_{11,t} - 295 D_{48,t} \\
 & + 4433 H_{2,t} - 261 D_{10,t} - 332 D_{16,t} - 213 D_{47,t} + 158 D_{43,t} \\
 & + 130 D_{27,t} + 65 M_{36,t} + 76 M_{37,t} + 92 M_{39,t} + 82 M_{38,t} \\
 & + 113 D_{28,t} + 87 M_{40,t} - 121 D_{46,t} + 111 M_{41,t} + 147 M_{42,t} \\
 & - 66 M_{35,t} + 95,0 D_{29,t} - 139 D_{24,t} - 7,5 D_{45,t} + 45,3 D_{44,t} \\
 & + 164 M_{43,t} - 129 D_{25,t} - 182 D_{17,t} - 76 S_{35,t} + 102 D_{34,t} \\
 & - 66 S_{38,t} - 99 S_{39,t} + \varepsilon_t
 \end{aligned}$$

7) Model *Time Series Regression window 7*

$$\begin{aligned}
Y_t = & 3794 H_{7,t} - 0,0025 t + 4110 H_{1,t} + 4230 H_{6,t} + 636 D_{36,t} + 617 D_{37,t} \\
& + 578 D_{38,t} + 568 D_{39,t} + 521 D_{40,t} + 516 D_{35,t} - 629 D_{14,t} - 622 D_{13,t} \\
& + 449 D_{41,t} - 544 D_{7,t} - 539 D_{6,t} + 4524 H_{4,t} - 510 D_{5,t} - 488 D_{8,t} \\
& - 479 D_{4,t} + 4504 H_{3,t} + 4514 H_{5,t} - 475 D_{12,t} - 437 D_{3,t} - 408 D_{2,t} \\
& - 480 D_{15,t} + 320 D_{42,t} - 371 D_{9,t} - 358 D_{1,t} - 323 D_{11,t} - 294 D_{48,t} \\
& + 4407 H_{2,t} - 260 D_{10,t} - 332 D_{16,t} - 212 D_{47,t} + 158 D_{43,t} + 129 D_{27,t} \\
& + 66 M_{36,t} + 76 M_{37,t} + 92 M_{38,t} + 108 M_{39,t} + 87 M_{40,t} - 120 D_{46,t} \\
& + 112 D_{28,t} + 110 M_{41,t} + 147 M_{42,t} - 70 M_{35,t} + 94,8 D_{29,t} - 136 \\
& D_{24,t} - 6,1 D_{45,t} + 46,7 D_{44,t} + 164 M_{43,t} - 182 D_{17,t} - 128 D_{25,t} \\
& - 78 S_{35,t} + 104 D_{34,t} + \varepsilon_t
\end{aligned}$$

Berdasarkan model pada setiap *window* tersebut, kemudian dilakukan pengujian parameter secara serentak dengan taraf signifikansi sebesar 5%. Dari hasil pengujian pada Lampiran 32 - 38 terhadap ketujuh *window* diperoleh nilai *p-value* sebesar 0,000 yang berarti minimal terdapat satu parameter yang berpengaruh signifikan terhadap model. Kemudian dilanjutkan dengan pengujian secara parsial pada taraf signifikansi 5% untuk masing-masing model. Pada model *window* 1 dari 60 variabel yang digunakan terdapat 41 variabel yang berpengaruh signifikan terhadap pemakaian beban listrik sebagaimana terlampir pada Lampiran 32. Model *window* 2 terdapat 42 variabel yang signifikan dari 66 variabel seperti yang terlampir pada Lampiran 33. Berdasarkan Lampiran 34 untuk model *window* 3 terdapat 41 variabel yang signifikan dari 62 variabel. Selanjutnya untuk model *window* 4 berdasarkan Lampiran 35 diperoleh hasil bahwa terdapat 43 variabel yang signifikan dari 64 variabel. Pada model *window* 5 dari 60 variabel yang digunakan terdapat 17 variabel yang signifikan sesuai hasil pada Lampiran 36. Sedangkan pada model *window* 6 dan 7 berdasarkan Lampiran 37 dan 38, sama-sama menghasilkan 42 variabel yang signifikan dari 57 variabel pada *window* 6 dan 55 variabel pada *window* 7.

Residual yang terbentuk dari ketujuh *window* belum *white noise* dan tidak berdistribusi normal berdasarkan hasil pada Lampiran 39, karena terdapat banyak data *outlier*. Berdasarkan ketujuh model dari setiap *window*, selanjutnya dilakukan peramalan pemakaian beban listrik untuk tanggal 24-30 September 2016 dan diperoleh nilai RMSE sebesar 158,358. *Time series plot* untuk perbandingan data aktual dengan hasil peramalan model *Time Series Regression* menggunakan variabel prediktor dari hasil pemilihan input tahap kedua metode *Random Forest* disajikan pada Gambar 4.29. Dari gambar tersebut dapat diketahui bahwa peramalan menggunakan hasil seleksi variabel pada tahap 2 (*Variabel selection for interpretation*) jauh lebih mendekati data aktual dibanding dengan peramalan dari hasil seleksi variabel pada tahap 3 (*Variabel selection for prediction*).




Gambar 4.29 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression* Menggunakan *Random Forest* Tahap 2.

Berdasarkan hasil seleksi variabel dengan *Random Forest* tahap 2 (*Variable selection for interpretation*) pada setiap *window*, akan dilakukan seleksi kembali untuk mengetahui variabel mana saja yang selalu terpilih di setiap *window*. Variabel dengan persentase tinggi untuk terpilih di setiap *window* merupakan variabel *dummy* yang paling berpengaruh terhadap pemakaian beban listrik di Jawa Timur. Rincian variabel yang terpilih di setiap *window* berdasarkan hasil *Random Forest* tahap kedua terlampir pada Lampiran 40. Pada analisis selanjutnya akan diambil variabel dengan persentase terpilih pada *window* 1 hingga 7 lebih dari 70% atau minimal variabel tersebut 5 kali terpilih dari 7 *window*. Variabel yang terpilih yaitu $t, D_1, D_2, D_3, D_4, D_5, D_6, D_7, D_8, D_9, D_{10}, D_{11}, D_{12}, D_{13}, D_{14}, D_{15}, D_{16}, D_{24}, D_{25}, D_{27}, D_{28}, D_{29}, D_{34}, D_{35}, D_{36}, D_{37}, D_{38}, D_{39}, D_{40}, D_{41}, D_{42}, D_{43}, D_{44}, D_{45}, D_{46}, D_{47}, D_{48}, H_1, H_2, H_3, H_4, H_5, H_6, H_7, S_{35}, S_{37}, S_{38}, S_{39}, S_{40}, S_{41}, M_{35}, M_{36}, M_{37}, M_{38}, M_{39}, M_{40}, M_{41}, M_{42}$, dan M_{43} . Jadi total variabel yang terpilih minimal 5 kali sebanyak 59 variabel.

59 variabel terpilih akan digunakan sebagai variabel prediktor pada model *time Series Regression* dengan prinsip *window time*. Akan tetapi, variabel prediktor yang digunakan di setiap *window* adalah sama yaitu 59 variabel yang terpilih di atas. Model yang terbentuk terlampir pada Lampiran 41 - 47. Berdasarkan model pada setiap *window* tersebut, kemudian dilakukan pengujian parameter secara serentak dengan taraf signifikansi sebesar 5%. Dari hasil pengujian pada Lampiran 42 - 47 terhadap ketujuh *window* diperoleh nilai *p-value* sebesar 0,000 yang berarti minimal terdapat satu parameter yang berpengaruh signifikan terhadap model. Kemudian dilanjutkan dengan pengujian secara parsial pada taraf signifikansi 5% untuk masing-masing model. Dari 59 variabel yang digunakan terdapat variabel signifikan secara berturut-turut pada *window* 1, *window* 2, *window* 3, *window* 4, *window* 5, *window* 6, dan *window* 7 sebanyak 41, 42, 41, 42, 41, 42, 41 variabel.

Residual yang terbentuk dari ketujuh *window* berdasarkan Lampiran 48 belum *white noise* karena plot ACF residual masih menunjukkan adanya lag yang keluar dari batas limit. Selain itu, residual tidak berdistribusi normal karena terdapat banyak data *outlier*. Berdasarkan ketujuh model dari setiap *window*, selanjutnya dilakukan peramalan pemakaian beban listrik untuk tanggal 24-30 September 2016 dan diperoleh nilai RMSE sebesar 159,0212. Perbandingan antara data aktual dengan hasil peramalan disajikan pada Gambar 4.30. Dari hasil peramalan ini ternyata menghasilkan nilai RMSE yang lebih besar dibanding dengan model *Time Series Regression* menggunakan variabel prediktor hasil seleksi *Random Forest* pada Tahap 2.



Gambar 4.30 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression* Menggunakan 59 Variabel.

4.3.2 Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode *Double Seasonal ARIMA* dengan Pemilihan Input Menggunakan *Random Forest*

Variabel input yang digunakan untuk diseleksi dengan *Random Forest* pada metode *Double Seasonal ARIMA* berupa lag Y_t . Banyaknya lag yang digunakan diperoleh berdasarkan model dasar atau model 1 pada pembahasan *Double Seasonal ARIMA* sub bab 4.2.2. Modelnya yaitu $ARIMA(0,1,1)(0,1,1)^{48}(0,1,1)^{336}$, jika dijabarkan maka persamaannya sebagai berikut.

$$(1-B)(1-B^{48})(1-B^{336})Y_t = (1-\theta_1 B)(1-\theta_2 B^{48})(1-\theta_3 B^{336})a_t$$

Sehingga,

$$Y_t = Y_{t-1} + Y_{t-48} - Y_{t-49} + Y_{t-336} - Y_{t-337} - Y_{t-384} + Y_{t-385} - \theta_1 a_{t-1} - \theta_2 a_{t-48} \\ + \theta_1 \theta_2 a_{t-49} + \theta_1 \theta_3 a_{t-327} - \theta_3 a_{t-336} + \theta_2 \theta_3 a_{t-384} - \theta_1 \theta_2 \theta_3 a_{t-385} + a_t$$

$$Y_t = f(Y_{t-1}, Y_{t-48}, Y_{t-49}, Y_{t-336}, Y_{t-337}, Y_{t-384}, Y_{t-385}) + f(a_{t-1}, a_{t-48}, a_{t-49} \\ a_{t-327}, a_{t-336}, a_{t-384}, a_{t-385}) + a_t$$

Dari model tersebut, maka banyaknya lag yang digunakan untuk proses seleksi menggunakan *Random Forest* sebanyak 385 lag. Banyaknya lag yang digunakan mengacu langkah-langkah hasil simulasi pada sub bab 2.4. Sehingga Y_t pada analisis ini dapat dituliskan menjadi persamaan berikut.

$$Y_t = f(Y_{t-1}, Y_{t-48}, Y_{t-49}, Y_{t-336}, Y_{t-337}, Y_{t-384}, Y_{t-385}) + a_t$$

Hasil seleksi dari 385 lag menggunakan *Random Forest* disajikan pada Tabel 4.14.

Tabel 4.14 Hasil Pemilihan Lag pada Window 1 – 7 dengan *Random Forest*.

Window	Banyaknya	Variabel Terseleksi
Window 1	60 variabel	$Y_{t-1}, Y_{t-2}, Y_{t-336}, Y_{t-3}, Y_{t-48}, Y_{t-335}, Y_{t-337},$ $Y_{t-288}, Y_{t-5}, Y_{t-383}, Y_{t-18}, Y_{t-11}, Y_{t-338}, Y_{t-192},$ $Y_{t-29}, Y_{t-239}, Y_{t-147}, Y_{t-36}, Y_{t-57}, Y_{t-349},$ $Y_{t-21}, Y_{t-299}, Y_{t-348}, Y_{t-339}, Y_{t-146}, Y_{t-359}$

Tabel 4.14 Hasil Pemilihan Lag pada Window 1 – 7 dengan *Random Forest* (Lanjutan).

Window	Banyaknya	Variabel Terseleksi
Window 2	66 variabel	$Y_{t-1}, Y_{t-2}, Y_{t-336}, Y_{t-3}, Y_{t-335}, Y_{t-48}, Y_{t-337},$ $Y_{t-288}, Y_{t-5}, Y_{t-383}, Y_{t-11}, Y_{t-18}, Y_{t-382}, Y_{t-338},$ $Y_{t-37}, Y_{t-192}, Y_{t-29}, Y_{t-351}, Y_{t-285}, Y_{t-191},$ $Y_{t-36}, Y_{t-22}, Y_{t-147}, Y_{t-321}, Y_{t-349}, Y_{t-25}, Y_{t-352},$ $Y_{t-56}, Y_{t-195}, Y_{t-339}$
Window 3	62 variabel	$Y_{t-1}, Y_{t-2}, Y_{t-336}, Y_{t-3}, Y_{t-335}, Y_{t-48}, Y_{t-337},$ $Y_{t-288}, Y_{t-334}, Y_{t-11}, Y_{t-18}, Y_{t-9}, Y_{t-286}, Y_{t-382},$ $Y_{t-10}, Y_{t-338}, Y_{t-192}, Y_{t-29}, Y_{t-351}, Y_{t-191},$ $Y_{t-147}, Y_{t-348}, Y_{t-339}, Y_{t-325}, Y_{t-195}$
Window 4	64 variabel	$Y_{t-1}, Y_{t-2}, Y_{t-336}, Y_{t-3}, Y_{t-335}, Y_{t-48}, Y_{t-337},$ $Y_{t-288}, Y_{t-9}, Y_{t-11}, Y_{t-286}, Y_{t-338}, Y_{t-382}, Y_{t-19},$ $Y_{t-240}, Y_{t-29}, Y_{t-351}, Y_{t-13}, Y_{t-350}, Y_{t-147},$ $Y_{t-20}, Y_{t-191}, Y_{t-22}, Y_{t-320}, Y_{t-195}, Y_{t-25}, Y_{t-381}$
Window 5	60 variabel	$Y_{t-1}, Y_{t-2}, Y_{t-336}, Y_{t-3}, Y_{t-335}, Y_{t-48}, Y_{t-337},$ $Y_{t-288}, Y_{t-334}, Y_{t-383}, Y_{t-11}, Y_{t-9}, Y_{t-7}, Y_{t-338},$ $Y_{t-382}, Y_{t-37}, Y_{t-239}, Y_{t-15}, Y_{t-29}, Y_{t-147},$ $Y_{t-13}, Y_{t-144}, Y_{t-351}, Y_{t-284}, Y_{t-350}, Y_{t-191},$ $Y_{t-320}, Y_{t-194}, Y_{t-25}, Y_{t-26}$
Window 6	57 variabel	$Y_{t-1}, Y_{t-2}, Y_{t-336}, Y_{t-3}, Y_{t-48}, Y_{t-335}, Y_{t-337},$ $Y_{t-288}, Y_{t-334}, Y_{t-11}, Y_{t-18}, Y_{t-286}, Y_{t-382}, Y_{t-37},$ $Y_{t-240}, Y_{t-239}, Y_{t-29}, Y_{t-338}, Y_{t-147}, Y_{t-351},$ Y_{t-57}, Y_{t-321}
Window 7	55 variabel	$Y_{t-1}, Y_{t-2}, Y_{t-336}, Y_{t-3}, Y_{t-48}, Y_{t-335}, Y_{t-337},$ $Y_{t-288}, Y_{t-334}, Y_{t-11}, Y_{t-382}, Y_{t-286}, Y_{t-17}, Y_{t-239},$ $Y_{t-385}, Y_{t-19}, Y_{t-338}, Y_{t-14}, Y_{t-29}, Y_{t-147}, Y_{t-282},$ $Y_{t-381}, Y_{t-351}, Y_{t-350}, Y_{t-324}$

Lag yang terseleksi menggunakan metode *Random Forest*, selanjutnya digunakan sebagai subset AR (p) pada model *Double Seasonal* ARIMA. Sehingga menghasilkan model untuk setiap *window* sebagai berikut.

Tabel 4.15 Model *Double Seasonal* ARIMA dengan Pemilihan Input Menggunakan *Random Forest*.

Window	Model ARIMA
Window 1	$([1,2,3,5,11,18,21,29,36,48,57,146,147,192,239,288,299,335,336,337,338,339,348,349,359,383],1,1)(0,1,1)^{48}$ $(0,1,1)^{336}$
Window 2	$([1,2,3,5,11,18,22,25,29,36,37,48,56,147,191,192,195,285,288,321,335,336,337,338,339,349,351,352,382,383],1,1)$ $(0,1,1)^{48} (0,1,1)^{336}$
Window 3	$([1,2,3,9,10,11,18,29,48,147,191,192,195,286,288,325,334,335,336,337,338,339,348,351,382],1,1) (0,1,1)^{48} (0,1,1)^{336}$
Window 4	$([1,2,3,9,11,13,19,20,22,25,29,48,147,191,195,240,286,288,320,335,336,337,338,350,351,381,382],1,1)(0,1,1)^{48}$ $(0,1,1)^{336}$
Window 5	$([1,2,3,7,9,11,13,15,25,26,29,37,48,144,147,191,194,239,284,288,320,334,335,336,337,338,350,351,382,383],1,1)$ $(0,1,1)^{48} (0,1,1)^{336}$
Window 6	$([1,2,3,11,18,29,37,48,57,147,239,240,286,288,321,334,335,336,337,338,351,382],1,1)(0,1,1)^{48} (0,1,1)^{336}$
Window 7	$([1,2,3,11,14,17,19,29,48,147,239,282,286,288,324,334,335,336,337,338,351,381,382,385],1,1) (0,1,1)^{48} (0,1,1)^{336}$

Dari model yang terbentuk kemudian dilakukan estimasi dan pengujian parameter model dugaan yang terlampir pada Lampiran 58, 60, 62, 64, 66, 68, dan 70. Pada taraf kepercayaan 95% ($\alpha = 0,05$) banyaknya parameter yang signifikan pada masing-masing *window* sebanyak 39 parameter pada *window* 1, 41 parameter pada *window* 2, 38 parameter pada *window* 3, 42 parameter pada *window* 4, 33 parameter pada *window* 5, 37 parameter pada *window* 6, dan 36 parameter pada *window* 7.

Setelah dilakukan estimasi dan pengujian signifikansi parameter, selanjutnya menguji kesesuaian model berdasarkan residual model yang terbentuk. Pengujian residual terdiri dari pengujian *white noise* menggunakan uji Ljung-Box-Pierce dan pengujian distribusi normal menggunakan uji Kolmogorov-Smirnov. Hasil uji Ljung-Box-Pierce pada Tabel 4.16 menunjukkan bahwa model pada *window* 1 hingga 7 residualnya belum *white noise* karena nilai *p-value* hingga lag ke-48 kurang dari $\alpha = 0,05$. Pengujian distribusi normal menggunakan uji Kolmogorov-Smirnov yang disajikan pada Tabel 4.17 yang menunjukkan bahwa residual model *window* 1 hingga 7 tidak memenuhi asumsi distribusi normal berdasarkan nilai *p-value* yang kurang dari $\alpha = 0,05$. Hal ini disebabkan karena data pemakaian beban listrik di Jawa Timur memiliki banyak *outlier* seperti yang ditunjukkan pada Gambar 4.20. Perbandingan antara data aktual dengan peramalan 7 hari kedepan ditampilkan pada Gambar 4.31 dengan nilai RMSE sebesar 149,0967.

Tabel 4.16 Uji Asumsi Residual *White Noise* pada Dugaan Model *Double Seasonal ARIMA* dengan *Random Forest*.

Model	Hingga Lag	<i>Chi-Square</i>	<i>df</i>	<i>p-value</i>
<i>Window 1</i>	6	.	0	.
	12	.	0	.
	18	.	0	.
	24	.	0	.
	30	46.89	1	<.0001
	36	53.70	7	<.0001
	42	67.41	13	<.0001
	48	74.55	19	<.0001
<i>Window 2</i>	6	.	0	.
	12	.	0	.
	18	.	0	.
	24	.	0	.
	30	.	0	.
	36	47.63	3	<.0001
	42	57.90	9	<.0001
	48	62.42	15	<.0001

Tabel 4.16 Uji Asumsi Residual *White Noise* pada Dugaan Model *Double Seasonal* ARIMA dengan *Random Forest* (Lanjutan).


<i>Window</i>	Hingga Lag	<i>Chi-Square</i>	<i>df</i>	<i>p-value</i>
<i>Window 3</i>	6	.	0	.
	12	.	0	.
	18	.	0	.
	24	.	0	.
	30	51.30	2	<.0001
	36	54.27	8	<.0001
	42	64.43	14	<.0001
	48	71.72	20	<.0001
<i>Window 4</i>	6	.	0	.
	12	.	0	.
	18	.	0	.
	24	.	0	.
	30	.	0	.
	36	47.65	6	<.0001
	42	60.91	12	<.0001
	48	74.31	18	<.0001
<i>Window 5</i>	6	.	0	.
	12	.	0	.
	18	.	0	.
	24	.	0	.
	30	.	0	.
	36	57.42	3	<.0001
	42	62.63	9	<.0001
	48	75.82	15	<.0001
<i>Window 6</i>	6	.	0	.
	12	.	0	.
	18	.	0	.
	24	.	0	.
	30	43.30	5	<.0001
	36	47.55	11	<.0001
	42	52.04	17	<.0001
	48	64.93	23	<.0001

Tabel 4.16 Uji Asumsi Residual *White Noise* pada Dugaan Model *Double Seasonal ARIMA* dengan *Random Forest* (Lanjutan).

Window	Hingga Lag	Chi-Square	df	p-value
Window 7	6	.	0	.
	12	.	0	.
	18	.	0	.
	24	.	0	.
	30	46.13	3	<.0001
	36	48.41	9	<.0001
	42	57.01	15	<.0001
	48	69.98	21	<.0001

Tabel 4.17 Uji Asumsi Residual Distribusi Normal pada Dugaan Model *Double Seasonal ARIMA* dengan *Random Forest*.

Window	Kolmogorov-Smirnov	p-value
Window 1	0,053	<0,010
Window 2	0,056	<0,010
Window 3	0,054	<0,010
Window 4	0,059	<0,010
Window 5	0,061	<0,010
Window 6	0,058	<0,010
Window 7	0,055	<0,010



Gambar 4.31 Perbandingan Data Aktual dengan Peramalan Model *Double Seasonal ARIMA* dengan *Random Forest*.

4.4 Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode *Time Series Regression* dan *Double Seasonal ARIMA* dengan Pemilihan Input Menggunakan Metode *Stepwise*

Pada penelitian ini juga dilakukan analisis mengenai pemilihan input dengan metode yang sederhana yaitu metode *Stepwise*. Hasil pemilihan input tersebut kemudian dimodelkan menggunakan Model *Time Series Regression* dan *Double Seasonal ARIMA*. Selanjutnya akan dibandingkan hasil peramalannya berdasarkan kriteria nilai RMSE antara model dengan pemilihan input menggunakan *Stepwise* dan *Random Forest*. Data yang digunakan pada pemodelan ini menggunakan prinsip *window time* seperti yang telah dijelaskan pada sub bab 4.3.

4.4.1 Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode *Time Series Regression* dengan Pemilihan Input Menggunakan Metode *Stepwise*

Metode *Stepwise* digunakan untuk menyeleksi 157 variabel *dummy* yang selanjutnya digunakan sebagai variabel prediktor pada model *Time Series Regression*. Hasil seleksi variabel dengan metode *Stepwise* disajikan pada Tabel 4.18.

Tabel 4.18 *Dummy* Terpilih pada Model *Time Series Regression* dengan Metode *Stepwise*.

<i>Window</i>	Banyaknya	Variabel Terseleksi
<i>Window 1</i>	85 variabel (step ke-91)	$H_{4,t}, H_{6,t}, H_{5,t}, H_{2,t}, H_{3,t}, H_{1,t}, H_{7,t}, D_{36,t}, D_{37,t},$ $D_{38,t}, D_{39,t}, D_{40,t}, D_{35,t}, D_{41,t}, D_{42,t}, D_{14,t}, D_{13,t},$ $D_{7,t}, D_{6,t}, D_{5,t}, D_{8,t}, D_{15,t}, D_{4,t}, D_{12,t}, D_{3,t}, D_{2,t},$ $D_{9,t}, D_{1,t}, D_{16,t}, D_{11,t}, D_{48,t}, D_{10,t}, D_{43,t}, D_{47,t},$ $D_{17,t}, D_{24,t}, M_{18,t}, D_{25,t}, M_{19,t}, M_{20,t}, D_{46,t}, M_{21,t},$ $M_{30,t}, M_{29,t}, M_{23,t}, M_{22,t}, M_{26,t}, M_{28,t}, M_{27,t}, M_{31,t},$ $M_{32,t}, M_{33,t}, D_{18,t}, M_{17,t}, D_{27,t}, M_{24,t}, M_{25,t}, D_{28,t},$ $M_{16,t}, M_{34,t}, S_{5,t}, S_{2,t}, S_{4,t}, S_{3,t}, S_{7,t}, S_{1,t}, S_{6,t},$ $S_{12,t}, S_{8,t}, S_{10,t}, S_{9,t}, S_{11,t}, D_{29,t}, D_{45,t}, J_{3,t}, S_{13,t},$

Tabel 4.18 *Dummy* Terpilih pada Model *Time Series Regression* dengan Metode *Stepwise* (Lanjutan).

Window	Banyaknya	Variabel Terseleksi
		$M_{1,t}, M_{3,t}, M_{4,t}, M_{6,t}, M_{5,t}, M_{2,t}, M_{7,t}, M_{8,t}, M_{9,t}$
Window 2	90 variabel (step ke-94)	$t, H_{5,t}, H_{2,t}, H_{1,t}, H_{6,t}, H_{3,t}, H_{4,t}, H_{7,t}, D_{36,t},$ $D_{37,t}, D_{38,t}, D_{39,t}, D_{40,t}, D_{35,t}, D_{41,t}, D_{42,t},$ $D_{14,t}, D_{13,t}, D_{7,t}, D_{6,t}, D_{5,t}, D_{8,t}, D_{15,t}, D_{4,t},$ $D_{12,t}, D_{3,t}, D_{2,t}, D_{9,t}, D_{1,t}, D_{16,t}, D_{11,t}, D_{48,t},$ $D_{10,t}, D_{47,t}, D_{43,t}, D_{17,t}, D_{24,t}, M_{18,t}, D_{25,t},$ $M_{19,t}, M_{20,t}, D_{46,t}, M_{21,t}, M_{30,t}, M_{29,t}, M_{23,t},$ $M_{22,t}, M_{26,t}, M_{28,t}, M_{27,t}, M_{31,t}, M_{32,t}, M_{33,t},$ $M_{17,t}, D_{18,t}, M_{24,t}, D_{27,t}, M_{25,t}, D_{28,t}, S_{28,t},$ $M_{16,t}, S_{5,t}, S_{2,t}, M_{34,t}, S_{4,t}, S_{3,t}, S_{1,t}, S_{7,t}, S_{9,t},$ $S_{12,t}, S_{10,t}, S_{8,t}, S_{6,t}, S_{11,t}, M_{35,t}, S_{13,t}, D_{45,t},$ $J_{3,t}, S_{14,t}, D_{29,t}, S_{29,t}, M_{1,t}, M_{3,t}, M_{4,t}, M_{6,t},$ $M_{5,t}, M_{2,t}, M_{7,t}, M_{8,t}, M_{9,t}$
Window 3	89 variabel (step ke-93)	$t, H_{2,t}, H_{1,t}, H_{3,t}, H_{6,t}, H_{4,t}, H_{5,t}, H_{7,t}, D_{36,t},$ $D_{37,t}, D_{38,t}, D_{39,t}, D_{40,t}, D_{35,t}, D_{41,t}, D_{42,t},$ $D_{14,t}, D_{13,t}, D_{43,t}, D_{7,t}, D_{6,t}, D_{5,t}, D_{15,t}, D_{8,t},$ $D_{4,t}, D_{12,t}, D_{3,t}, D_{2,t}, D_{9,t}, D_{16,t}, D_{1,t}, D_{11,t},$ $D_{48,t}, D_{10,t}, D_{47,t}, D_{17,t}, M_{18,t}, M_{19,t}, D_{24,t},$ $M_{20,t}, D_{25,t}, M_{30,t}, M_{29,t}, M_{21,t}, M_{26,t}, M_{23,t},$ $M_{22,t}, M_{27,t}, M_{28,t}, D_{46,t}, M_{31,t}, M_{32,t}, M_{33,t},$ $M_{17,t}, D_{18,t}, M_{24,t}, M_{25,t}, D_{27,t}, M_{16,t}, M_{34,t},$ $S_{5,t}, S_{2,t}, S_{4,t}, S_{3,t}, S_{12,t}, S_{10,t}, S_{9,t}, S_{1,t}, S_{7,t},$ $S_{8,t}, S_{11,t}, S_{6,t}, D_{28,t}, S_{13,t}, D_{45,t}, M_{1,t}, S_{14,t},$ $M_{6,t}, M_{4,t}, M_{3,t}, M_{5,t}, M_{2,t}, M_{7,t}, M_{8,t}, J_{3,t},$ $M_{9,t}, S_{28,t}, D_{29,t}, S_{29,t}$

Tabel 4.18 *Dummy* Terpilih pada Model *Time Series Regression* dengan Metode *Stepwise* (Lanjutan).

Window	Banyaknya	Variabel Terseleksi
Window 4	88 variabel (step ke-94)	$t, H_{2,t}, H_{3,t}, H_{4,t}, H_{5,t}, H_{1,t}, H_{7,t}, H_{6,t}, D_{36,t},$ $D_{37,t}, D_{38,t}, D_{39,t}, D_{40,t}, D_{35,t}, D_{41,t}, D_{42,t},$ $D_{14,t}, D_{13,t}, D_{7,t}, D_{6,t}, D_{5,t}, D_{15,t}, D_{8,t}, D_{4,t},$ $D_{12,t}, D_{3,t}, D_{2,t}, D_{9,t}, D_{1,t}, D_{16,t}, D_{11,t}, D_{48,t},$ $D_{10,t}, D_{43,t}, D_{47,t}, D_{17,t}, M_{18,t}, M_{19,t}, D_{24,t},$ $M_{20,t}, D_{25,t}, M_{30,t}, M_{29,t}, D_{46,t}, M_{21,t}, M_{26,t},$ $M_{23,t}, M_{22,t}, M_{27,t}, M_{28,t}, M_{31,t}, M_{32,t}, M_{33,t},$ $M_{17,t}, D_{18,t}, M_{24,t}, M_{25,t}, D_{27,t}, M_{16,t}, M_{34,t},$ $D_{28,t}, D_{45,t}, M_{35,t}, S_{4,t}, S_{5,t}, S_{2,t}, S_{3,t}, S_{1,t},$ $S_{9,t}, S_{8,t}, S_{6,t}, S_{7,t}, S_{12,t}, S_{10,t}, S_{11,t}, M_{1,t}, D_{29,t},$ $M_{6,t}, M_{4,t}, M_{3,t}, M_{2,t}, M_{5,t}, M_{7,t}, M_{8,t}, M_{9,t},$ $J_{3,t}, S_{13,t}, S_{14,t}$
Window 5	89 variabel (step ke-95)	$t, H_{3,t}, H_{4,t}, H_{2,t}, H_{5,t}, H_{1,t}, H_{6,t}, H_{7,t}, D_{36,t},$ $D_{37,t}, D_{38,t}, D_{39,t}, D_{40,t}, D_{35,t}, D_{41,t}, D_{42,t},$ $D_{14,t}, D_{13,t}, D_{7,t}, D_{6,t}, D_{5,t}, D_{8,t}, D_{4,t}, D_{15,t},$ $D_{12,t}, D_{3,t}, D_{2,t}, D_{9,t}, D_{1,t}, D_{16,t}, D_{11,t}, D_{48,t},$ $D_{10,t}, D_{47,t}, D_{17,t}, D_{43,t}, D_{24,t}, M_{18,t}, D_{25,t},$ $D_{46,t}, M_{19,t}, M_{20,t}, M_{30,t}, M_{29,t}, M_{21,t}, M_{26,t},$ $M_{27,t}, M_{22,t}, M_{23,t}, M_{28,t}, M_{31,t}, M_{32,t}, D_{18,t},$ $M_{33,t}, M_{17,t}, M_{24,t}, M_{25,t}, D_{27,t}, D_{28,t}, M_{16,t},$ $M_{34,t}, S_{4,t}, S_{5,t}, S_{2,t}, S_{3,t}, S_{1,t}, S_{9,t}, S_{6,t}, S_{7,t},$ $S_{8,t}, S_{12,t}, S_{10,t}, S_{11,t}, M_{35,t}, D_{45,t}, D_{29,t}, M_{1,t},$ $S_{13,t}, J_{3,t}, M_{4,t}, M_{6,t}, M_{3,t}, M_{5,t}, M_{2,t}, M_{7,t},$ $M_{8,t}, M_{9,t}, S_{14,t}, S_{19,t}$

Tabel 4.18 *Dummy* Terpilih pada Model *Time Series Regression* dengan Metode *Stepwise* (Lanjutan).


Window	Banyaknya	Variabel Terseleksi
Window 6	88 variabel (step ke-92)	$H_{4,t}, H_{2,t}, H_{5,t}, H_{3,t}, H_{6,t}, H_{1,t}, H_{7,t}, D_{36,t},$ $D_{37,t}, D_{38,t}, D_{39,t}, D_{40,t}, D_{35,t}, D_{41,t}, D_{42,t},$ $D_{14,t}, D_{13,t}, D_{7,t}, D_{6,t}, D_{5,t}, D_{8,t}, D_{15,t}, D_{4,t},$ $D_{12,t}, D_{3,t}, D_{2,t}, D_{9,t}, D_{1,t}, D_{16,t}, D_{11,t}, D_{48,t},$ $D_{10,t}, D_{47,t}, D_{17,t}, D_{43,t}, D_{24,t}, M_{18,t}, D_{25,t},$ $D_{46,t}, M_{19,t}, M_{20,t}, M_{30,t}, M_{29,t}, M_{21,t}, M_{26,t},$ $M_{27,t}, M_{22,t}, M_{23,t}, M_{28,t}, M_{31,t}, M_{32,t}, M_{33,t},$ $D_{18,t}, M_{17,t}, M_{24,t}, M_{25,t}, D_{27,t}, D_{28,t}, M_{16,t},$ $M_{34,t}, D_{45,t}, M_{35,t}, S_{4,t}, S_{5,t}, S_{2,t}, S_{3,t}, S_{1,t},$ $S_{9,t}, S_{6,t}, S_{7,t}, S_{8,t}, S_{12,t}, S_{10,t}, S_{11,t}, D_{29,t}, M_{1,t},$ $S_{13,t}, J_{3,t}, M_{6,t}, M_{4,t}, M_{3,t}, M_{5,t}, M_{2,t}, M_{7,t},$ $M_{8,t}, M_{9,t}, S_{14,t}, D_{19,t}$
Window 7	88 variabel (step ke-92)	$H_{5,t}, H_{3,t}, H_{4,t}, H_{6,t}, H_{2,t}, H_{1,t}, H_{7,t}, D_{36,t},$ $D_{37,t}, D_{38,t}, D_{39,t}, D_{40,t}, D_{35,t}, D_{41,t}, D_{42,t},$ $D_{14,t}, D_{13,t}, D_{7,t}, D_{6,t}, D_{5,t}, D_{8,t}, D_{15,t}, D_{4,t},$ $D_{12,t}, D_{3,t}, D_{2,t}, D_{9,t}, D_{1,t}, D_{16,t}, D_{11,t}, D_{48,t},$ $D_{10,t}, D_{47,t}, D_{17,t}, D_{43,t}, D_{24,t}, M_{18,t}, D_{25,t},$ $D_{46,t}, M_{19,t}, M_{20,t}, M_{30,t}, M_{29,t}, M_{21,t}, M_{26,t},$ $M_{27,t}, M_{22,t}, M_{23,t}, M_{28,t}, M_{31,t}, M_{32,t}, M_{33,t},$ $D_{18,t}, M_{17,t}, M_{24,t}, M_{25,t}, D_{27,t}, D_{28,t}, M_{16,t},$ $M_{34,t}, D_{45,t}, M_{35,t}, S_{2,t}, S_{4,t}, S_{5,t}, S_{3,t}, S_{1,t},$ $S_{6,t}, S_{9,t}, S_{7,t}, S_{8,t}, S_{12,t}, S_{10,t}, S_{11,t}, D_{29,t}, S_{13,t},$ $J_{3,t}, M_{1,t}, M_{6,t}, M_{3,t}, M_{4,t}, M_{5,t}, M_{2,t}, M_{7,t},$ $M_{8,t}, S_{14,t}, M_{9,t}, D_{19,t}$

Hasil seleksi variabel menggunakan metode *Stepwise* untuk masing-masing *window* selanjutnya digunakan untuk menentukan model *Time Series Regresion* seperti yang terlampir pada Lampiran 71 – 77. Berdasarkan model yang terbentuk, kemudian dilakukan pengujian parameter secara serentak untuk masing-masing *window* dengan taraf signifikansi sebesar 5%. Dari hasil pengujian pada Lampiran 71 - 77 terhadap ketujuh *window* diperoleh nilai *p-value* sebesar 0,000 yang berarti minimal terdapat satu parameter yang berpengaruh signifikan terhadap model. Lalu dilanjutkan dengan pengujian secara parsial pada taraf signifikansi 5% untuk mengetahui parameter yang signifikan. Ketujuh *window* menghasilkan kesimpulan yang sama yaitu keseluruhan variabel yang digunakan pada masing-masing *window* telah signifikan terhadap model. Hal ini karena pemilihan variabel dengan metode *Stepwise* memperhatikan nilai signifikansi dengan $\alpha = 0,05$.

Selain itu, residual dari ketujuh *window* belum *white noise* berdasarkan hasil pada Lampiran 78, karena pada plot ACF residual masih terdapat lag yang keluar dari batas limitnya. Kemudian residual model dari keseluruhan *window* tersebut tidak berdistribusi normal. Karena berdasarkan hasil pengujian Kolmogorov-Smirnov pada Tabel 4.19 diperoleh nilai *p-value* kurang dari $\alpha = 0,05$. Berdasarkan ketujuh model dari setiap *window* yang terbentuk selanjutnya dilakukan peramalan pemakaian beban listrik dan diperoleh nilai RMSE sebesar 105,3394. Perbandingan antara data aktual dengan peramalan 7 hari kedepan ditampilkan pada Gambar 4.32.

Tabel 4.19 Uji Asumsi Residual Distribusi Normal Dugaan Model *Time Series Regression* dengan *Stepwise*.

<i>Window</i>	Kolmogorov-Smirnov	<i>p-value</i>
<i>Window 1</i>	0,202	<0,010
<i>Window 2</i>	0,207	<0,010
<i>Window 3</i>	0,204	<0,010
<i>Window 4</i>	0,203	<0,010
<i>Window 5</i>	0,196	<0,010
<i>Window 6</i>	0,184	<0,010
<i>Window 7</i>	0,192	<0,010



Gambar 4.32 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression* Menggunakan Metode *Stepwise*.

Residual yang tidak *white noise* dari model di atas diduga karena terdapat lag yang berpengaruh terhadap pemakaian beban listrik. Hal ini diketahui berdasarkan Lampiran 78 untuk plot ACF residual dimana pada plot tersebut terlihat lag 1 dan 336 keluar dari batas limit. Sehingga analisis ini dilanjutkan dengan menambahkan lag 1 dan 336 sebagai variabel prediktor yang selanjutnya akan diseleksi menggunakan metode *Stepwise*. Jadi total variabel prediktor yang digunakan sebanyak 159 variabel. Penambahan lag pada variabel prediktor model *Time Series Regression* diharapkan mampu mengatasi residual yang tidak *white noise*. Hasil seleksi seluruh variabel dengan metode *Stepwise* terlampir pada Lampiran 79. Berdasarkan lampiran tersebut, diketahui bahwa lag Y_{t-1} selalu terleksi di setiap *window*. Hal ini menunjukkan bahwa lag Y_{t-1} berpengaruh signifikan terhadap pemakaian beban listrik di Jawa Timur.


Hasil seleksi variabel menggunakan metode *Stepwise* untuk masing-masing *window* selanjutnya digunakan untuk menentukan model *Time Series Regression* seperti yang terlampir pada Lampiran 80 – 86. Berdasarkan model yang terbentuk, kemudian

dilakukan pengujian parameter secara serentak untuk masing-masing *window* dengan taraf signifikansi sebesar 5%. Dari hasil pengujian pada Lampiran 80-86 terhadap ketujuh *window* diperoleh nilai *p-value* sebesar 0,000 yang berarti minimal terdapat satu parameter yang berpengaruh signifikan terhadap model. Lalu dilanjutkan dengan pengujian secara parsial pada taraf signifikansi 5% untuk mengetahui parameter yang signifikan. Ketujuh *window* menghasilkan kesimpulan yang sama yaitu keseluruhan variabel yang digunakan pada masing-masing *window* telah signifikan terhadap model. Hal ini karena pemilihan variabel dengan metode *Stepwise* memperhatikan nilai signifikansi dengan $\alpha = 0,05$.

Residual model pada masing-masing *window* belum *white noise* berdasarkan plot ACF residual pada Lampiran 87, tetapi sudah mendekati *white noise* karena lag yang keluar dari batas limitnya tidak sebanyak pada model *Time Series Regression* yang tidak melibatkan lag Y_t sebagai variabel prediktor. Kemudian residual model dari keseluruhan *window* tersebut tidak berdistribusi normal. Karena berdasarkan hasil pengujian Kolmogorov-Smirnov pada Tabel 4.20 diperoleh nilai *p-value* kurang dari $\alpha = 0,05$. Berdasarkan ketujuh model dari setiap *window* yang terbentuk selanjutnya dilakukan peramalan pemakaian beban listrik dan diperoleh nilai RMSE sebesar 390,566. Perbandingan antara data aktual dengan peramalan 7 hari kedepan ditampilkan pada Gambar 4.33.

Tabel 4.20 Uji Asumsi Residual Distribusi Normal Dugaan Model *Time Series Regression* yang Menyertakan Lag Y_t dengan *Stepwise*.

<i>Window</i>	Kolmogorov-Smirnov	<i>p-value</i>
<i>Window 1</i>	0,084	<0,010
<i>Window 2</i>	0,084	<0,010
<i>Window 3</i>	0,083	<0,010
<i>Window 4</i>	0,084	<0,010
<i>Window 5</i>	0,084	<0,010
<i>Window 6</i>	0,086	<0,010
<i>Window 7</i>	0,086	<0,010



Gambar 4.33 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression* yang Menyertakan Lag Y_t Menggunakan Metode *Stepwise* .

4.4.2 Analisis Peramalan Pemakaian Beban Listrik di Jawa Timur Menggunakan Metode *Double Seasonal ARIMA* dengan Pemilihan Input Menggunakan Metode *Stepwise*

Variabel input yang digunakan untuk proses seleksi dengan metode *Stepwise* pada model *Double Seasonal ARIMA* berupa lag Y_t . Terdapat 385 lag yang digunakan berdasarkan penjelasan pada sub bab 4.3.2. Berikut pada Tabel 4.21 disajikan hasil seleksi lag Y_t dengan metode *Stepwise*.

Tabel 4.21 Hasil Pemilihan Lag pada *Window 1 – 7* dengan *Stepwise*.

<i>Window</i>	Banyaknya	Variabel Terseleksi
<i>Window 1</i>	11 variabel (step ke-15)	$Y_{t-1}, Y_{t-15}, Y_{t-334}, Y_{t-335}, Y_{t-336}, Y_{t-337},$ $Y_{t-338}, Y_{t-340}, Y_{t-351}, Y_{t-384}, Y_{t-385}$
<i>Window 2</i>	13 variabel (step ke-19)	$Y_{t-1}, Y_{t-5}, Y_{t-288}, Y_{t-289}, Y_{t-290}, Y_{t-334}, Y_{t-335},$ $Y_{t-336}, Y_{t-337}, Y_{t-338}, Y_{t-340}, Y_{t-384}, Y_{t-385}$

Tabel 4.21 Hasil Pemilihan Lag pada *Window* 1 – 7 dengan *Stepwise*.
(Lanjutan).

<i>Window</i>	Banyaknya	Variabel Terseleksi
<i>Window</i> 3	13 variabel (step ke-19)	$Y_{t-1}, Y_{t-5}, Y_{t-288}, Y_{t-289}, Y_{t-290}, Y_{t-334}, Y_{t-335},$ $Y_{t-336}, Y_{t-337}, Y_{t-338}, Y_{t-340}, Y_{t-384}, Y_{t-385}$
<i>Window</i> 4	11 variabel (step ke-17)	$Y_{t-1}, Y_{t-15}, Y_{t-334}, Y_{t-335}, Y_{t-336}, Y_{t-337}, Y_{t-338},$ $Y_{t-340}, Y_{t-352}, Y_{t-384}, Y_{t-385}$
<i>Window</i> 5	13 variabel (step ke-25)	$Y_{t-1}, Y_{t-15}, Y_{t-288}, Y_{t-289}, Y_{t-290}, Y_{t-333}, Y_{t-335},$ $Y_{t-336}, Y_{t-337}, Y_{t-338}, Y_{t-351}, Y_{t-384}, Y_{t-385}$
<i>Window</i> 6	13 variabel (step ke-27)	$Y_{t-1}, Y_{t-15}, Y_{t-288}, Y_{t-289}, Y_{t-290}, Y_{t-335}, Y_{t-336},$ $Y_{t-337}, Y_{t-338}, Y_{t-351}, Y_{t-382}, Y_{t-384}, Y_{t-385}$
<i>Window</i> 7	13 variabel (step ke-29)	$Y_{t-1}, Y_{t-15}, Y_{t-288}, Y_{t-289}, Y_{t-290}, Y_{t-335}, Y_{t-336},$ $Y_{t-337}, Y_{t-338}, Y_{t-351}, Y_{t-382}, Y_{t-384}, Y_{t-385}$

Lag yang terseleksi menggunakan metode *Stepwise*, selanjutnya digunakan sebagai subset AR (p) pada model *Double Seasonal* ARIMA. Sehingga menghasilkan model pada Tabel 4.22 untuk masing-masing *window*.

Tabel 4.22 Model *Double Seasonal* ARIMA dengan Pemilihan Input Menggunakan Metode *Stepwise*.

<i>Window</i>	Model ARIMA
<i>Window</i> 1	$([1, 15, 334, 335, 336, 337, 338, 340, 351, 384, 385], 1, 1)(0, 1, 1)^{48}$ $(0, 1, 1)^{336}$
<i>Window</i> 2	$([1, 5, 288, 289, 290, 334, 335, 336, 337, 338, 340, 384, 385], 1, 1)$ $(0, 1, 1)^{48} (0, 1, 1)^{336}$
<i>Window</i> 3	$([1, 5, 288, 289, 290, 334, 335, 336, 337, 338, 340, 384, 385], 1, 1)$ $(0, 1, 1)^{48} (0, 1, 1)^{336}$
<i>Window</i> 4	$([1, 15, 334, 335, 336, 337, 338, 340, 352, 384, 385], 1, 1)(0, 1, 1)^{48}$ $(0, 1, 1)^{336}$

Tabel 4.22 Model *Double Seasonal* ARIMA dengan Pemilihan Input Menggunakan Metode *Stepwise* (Lanjutan).

Window	Model ARIMA
Window 5	$([1,15,288,289,290,333,335,336,337,338,351,384,385],1,1)$ $(0,1,1)^{48} (0,1,1)^{336}$
Window 6	$([1,15,288,289,290,335,336,337,338,351,382,384,385],1,1)$ $(0,1,1)^{48} (0,1,1)^{336}$
Window 7	$([1,15,288,289,290,335,336,337,338,351,382,384,385],1,1)$ $(0,1,1)^{48} (0,1,1)^{336}$

Dari model yang terbentuk kemudian dilakukan estimasi dan pengujian parameter model dugaan yang terlampir pada Lampiran 89, 91, 93, 95, 97, 99, dan 101. Pada taraf kepercayaan 95% ($\alpha = 0,05$) banyaknya parameter yang signifikan pada masing-masing *window* sebanyak 4 parameter pada *window* 1, 4 parameter pada *window* 2, 5 parameter pada *window* 3, 2 parameter pada *window* 4, 3 parameter pada *window* 5, 4 parameter pada *window* 6, dan 5 parameter pada *window* 7.

Setelah dilakukan estimasi dan pengujian signifikansi parameter, selanjutnya menguji kesesuaian model berdasarkan residual model yang terbentuk. Pengujian residual terdiri dari pengujian *white noise* menggunakan uji Ljung-Box-Pierce dan pengujian distribusi normal menggunakan uji Kolmogorov-Smirnov. Hasil uji Ljung-Box-Pierce pada Tabel 4.19 menunjukkan bahwa model pada *window* 1 hingga 7 residualnya belum *white noise* karena nilai *p-value* hingga lag ke-48 kurang dari $\alpha = 0,05$. Pengujian distribusi normal menggunakan uji Kolmogorov-Smirnov yang disajikan pada Tabel 4.20 yang menunjukkan bahwa residual model *window* 1 hingga 7 tidak memenuhi asumsi distribusi normal berdasarkan nilai *p-value* yang kurang dari $\alpha = 0,05$. Hal ini disebabkan karena data pemakaian beban listrik di Jawa Timur memiliki banyak *outlier*. Perbandingan antara data aktual dengan peramalan 7 hari kedepan ditampilkan pada Gambar 4.34 dengan nilai RMSE sebesar 149,7954.

Tabel 4.23 Uji Asumsi Residual *White Noise* pada Dugaan Model *Double Seasonal* ARIMA dengan *Stepwise*.


Model	Hingga Lag	Chi-Square	df	p-value
<i>Window 1</i>	6	.	0	.
	12	.	0	.
	18	41.22	4	<.0001
	24	62.26	10	<.0001
	30	72.53	16	<.0001
	36	80.71	22	<.0001
	42	95.67	28	<.0001
	48	103.53	34	<.0001
<i>Window 2</i>	6	.	0	.
	12	.	0	.
	18	29.00	2	<.0001
	24	47.70	8	<.0001
	30	54.49	14	<.0001
	36	59.61	20	<.0001
	42	69.56	26	<.0001
	48	75.44	32	<.0001
<i>Window 3</i>	6	.	0	.
	12	.	0	.
	18	27.89	2	<.0001
	24	43.60	8	<.0001
	30	52.73	14	<.0001
	36	56.06	20	<.0001
	42	66.70	26	<.0001
	48	74.90	32	<.0001
<i>Window 4</i>	6	.	0	.
	12	.	0	.
	18	36.64	4	<.0001
	24	53.31	10	<.0001
	30	63.23	16	<.0001
	36	66.47	22	<.0001
	42	77.50	28	<.0001
	48	91.67	34	<.0001

Tabel 4.23 Uji Asumsi Residual *White Noise* pada Dugaan Model *Double Seasonal ARIMA* dengan *Stepwise* (Lanjutan).

Model	Hingga Lag	Chi-Square	df	p-value
<i>Window 5</i>	6	.	0	.
	12	.	0	.
	18	37.39	2	<.0001
	24	57.66	8	<.0001
	30	68.12	14	<.0001
	36	71.72	20	<.0001
	42	80.14	26	<.0001
	48	92.62	32	<.0001
<i>Window 6</i>	6	.	0	.
	12	.	0	.
	18	36.16	2	<.0001
	24	49.85	8	<.0001
	30	60.11	14	<.0001
	36	64.72	20	<.0001
	42	72.12	26	<.0001
	48	90.99	32	<.0001
<i>Window 7</i>	6	.	0	.
	12	.	0	.
	18	33.06	2	<.0001
	24	47.13	8	<.0001
	30	57.91	14	<.0001
	36	60.77	20	<.0001
	42	67.11	26	<.0001
	48	80.73	32	<.0001

Tabel 4.24 Uji Asumsi Residual Distribusi Normal pada Dugaan Model *Double Seasonal ARIMA* dengan *Stepwise*.

Window	Kolmogorov-Smirnov	p-value
<i>Window 1</i>	0,059	<0,010
<i>Window 2</i>	0,061	<0,010
<i>Window 3</i>	0,061	<0,010
<i>Window 4</i>	0,064	<0,010
<i>Window 5</i>	0,059	<0,010
<i>Window 6</i>	0,056	<0,010
<i>Window 7</i>	0,060	<0,010



Gambar 4.34 Perbandingan Data Aktual dengan Peramalan Model *Double Seasonal ARIMA* dengan *Stepwise*.

4.5 Perbandingan Kebaikan Model


Dari hasil pembahasan pada sub bab 4.2, 4.3, dan 4.4 mengenai peramalan pemakaian beban listrik di Jawa Timur dengan metode *Time Series Regression* dan *Double Seasonal ARIMA* baik melalui proses seleksi variabel maupun tidak, diperoleh ramalan dengan nilai kebaikan model yang ditunjukkan pada Tabel 4.25. Kriteria kebaikan model yang digunakan untuk mengevaluasi seluruh model yang terbentuk menggunakan nilai RMSE.

Berdasarkan perbandingan nilai RMSE pada tabel di bawah, peramalan pemakaian beban listrik di Jawa Timur menggunakan *Time Series Regression* dengan seleksi variabel menggunakan metode *Stepwise* menghasilkan nilai RMSE terkecil. Sedangkan pada model *Double Seasonal ARIMA*, hasil peramalan terbaik menggunakan seleksi variabel dengan *Random Forest*. Jadi pada model *Time Series Regression*, pemilihan input dengan metode yang sederhana menggunakan *Stepwise* mampu menghasilkan peramalan yang lebih baik dibanding dengan metode *Random*


Forest. Pemilihan input dengan *Random Forest* dapat memperbaiki hasil peramalan pada model *Double Seasonal* ARIMA. Tetapi selisih nilai RMSE yang dihasilkan tidak terlalu berbeda jauh antara hasil seleksi dengan metode *Stepwise*. Sehingga metode seleksi variabel yang sederhana pun mampu menghasilkan variabel input dengan hasil peramalan yang baik. Perbandingan antara data aktual dengan hasil ramalan model *Time Series Regression* disajikan pada Gambar 4.35 dan untuk model *Double Seasonal* ARIMA disajikan pada Gambar 4.36.

Tabel 4.25 Perbandingan Nilai RMSE.


Pemilihan Input	Metode	RMSE
Tanpa pemilihan input (Data 1 Tahun)	TSR	
	- TSR (157 variabel)	156,7925
	- TSR + Variasi Kalender	115,1850
	- TSR + Variasi Kalender + Hari Libur Nasional	105,5292
	DSARIMA	156,5790
Tanpa pemilihan input (Data 1 Bulan)	TSR (157 variabel)	144,3417
	DSARIMA	251,5624
<i>Random Forest</i> (Data 1 Bulan)	TSR	
	- RF Tahap 3 (2 variabel)	2374,297
	- RF Tahap 2 (± 61 variabel)	158,3580
	- RF Tahap 2 (59 variabel)	159,0212
	DSARIMA (RF tahap 3)	149,0967
<i>Stepwise</i> (Data 1 Bulan)	TSR	
	- TSR (± 89 variabel)	105,3394
	- TSR + lag Y_t (± 72 variabel)	390,5660
	DSARIMA	149,7954





Gambar 4.35 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression* (a) Data 1 Tahun, (b) Penambahan Variasi Kalender, (c) Variasi Kalender dan Hari Libur, (d) Data 1 Bulan (e) Seleksi *Random Forest* Tahap 3, (f) Seleksi *Random Forest* Tahap 2, (g) Seleksi *Random Forest* Tahap 2 dengan 59 Variabel, (h) Seleksi *Stepwise*, (i) *Stepwise* dengan Lag Y_t .




Gambar 4.35 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression* (a) Data 1 Tahun, (b) Penambahan Variasi Kalender, (c) Variasi Kalender dan Hari Libur, (d) Data 1 Bulan (e) Seleksi *Random Forest* Tahap 3, (f) Seleksi *Random Forest* Tahap 2, (g) Seleksi *Random Forest* Tahap 2 dengan 59 Variabel, (h) Seleksi *Stepwise*, (i) *Stepwise* dengan Lag Y_t (Lanjutan).




Gambar 4.35 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression* (a) Data 1 Tahun, (b) Penambahan Variasi Kalender, (c) Variasi Kalender dan Hari Libur, (d) Data 1 Bulan (e) Seleksi *Random Forest* Tahap 3, (f) Seleksi *Random Forest* Tahap 2, (g) Seleksi *Random Forest* Tahap 2 dengan 59 Variabel, (h) Seleksi *Stepwise*, (i) *Stepwise* dengan Lag Y_t (Lanjutan).




Gambar 4.35 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression* (a) Data 1 Tahun, (b) Penambahan Variasi Kalender, (c) Variasi Kalender dan Hari Libur, (d) Data 1 Bulan (e) Seleksi *Random Forest* Tahap 3, (f) Seleksi *Random Forest* Tahap 2, (g) Seleksi *Random Forest* Tahap 2 dengan 59 Variabel, (h) Seleksi *Stepwise*, (i) *Stepwise* dengan Lag Y_t (Lanjutan).




Gambar 4.35 Perbandingan Data Aktual dengan Peramalan Model *Time Series Regression* (a) Data 1 Tahun, (b) Penambahan Variasi Kalender, (c) Variasi Kalender dan Hari Libur, (d) Data 1 Bulan (e) Seleksi *Random Forest* Tahap 3, (f) Seleksi *Random Forest* Tahap 2, (g) Seleksi *Random Forest* Tahap 2 dengan 59 Variabel, (h) Seleksi *Stepwise*, (i) Stepwise dengan Lag Y_t (Lanjutan).



Gambar 4.36 Perbandingan Data Aktual dengan Peramalan Model *Double Seasonal ARIMA* (a) Data 1 Tahun, (b) Data 1 Bulan, (c) Seleksi *Random Forest*, dan (d) Seleksi *Stepwise*.




Gambar 4.36 Perbandingan Data Aktual dengan Peramalan Model *Double Seasonal ARIMA* (a) Data 1 Tahun, (b) Data 1 Bulan, (c) Seleksi *Random Forest*, dan (d) Seleksi *Stepwise* (Lanjutan).



Gambar 4.36 Perbandingan Data Aktual dengan Peramalan Model *Double Seasonal ARIMA* (a) Data 1 Tahun, (b) Data 1 Bulan, (c) Seleksi *Random Forest*, dan (d) Seleksi *Stepwise* (Lanjutan).

Berdasarkan kedua model terbaik tersebut, kemudian dilakukan perhitungan nilai RMSE dan MAPE secara adaptif untuk mengetahui sampai berapa hari kedepan model tersebut baik dalam meramalkan pemakaian beban listrik di Jawa Timur. Pihak PT PLN (Persero) menetapkan *benchmark* kesalahan maksimum peramalan sebesar 2%. Jadi dari Gambar 4.37 (b) diketahui bahwa model *Double Seasonal ARIMA* dengan pemilihan input menggunakan *Random Forest* baik untuk meramalkan pemakaian beban listrik di Jawa Timur hingga 2 hari kedepan. Sedangkan model *Time Series Regression* dengan pemilihan input menggunakan *Stepwise* baik untuk meramalkan kurang dari 1 hari kedepan.



Gambar 4.37 Plot RMSE dan MAPE Adaptif (a) Model *Time Series Regression* dengan *Stepwise* dan (b) *Double Seasonal ARIMA* dengan *Random Forest*.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Setelah dilakukan analisis dan juga pembahasan pada Bab IV, berikut merupakan kesimpulan-kesimpulan yang dapat diambil dari penelitian ini yang berkaitan dengan latar belakang dan tujuan penelitian.

1. a. Rata-rata konsumsi listrik di Jawa Timur paling tinggi (*peak load*) terjadi pada pukul 18.30 sebesar 4747,5 MW dan paling rendah pada pukul 07.00 sebesar 3537,6 MW. Jika berdasarkan hari, maka konsumsi listrik paling tinggi pada hari Selasa yaitu sebesar 4220,6 MW dan terendah pada hari Minggu dengan rata-rata penggunaan sebesar 3646,2 MW. Naik turunnya pemakaian beban listrik juga dipengaruhi oleh hari libur nasional, bulan puasa, dan lebaran yang cenderung turun dari hari-hari biasa serta memiliki pola yang berbeda dengan pemakaian beban listrik hari biasa. Pada bulan puasa rata-rata pemakaian listrik tertinggi pada pukul 18.00 dan 20.00, sedangkan pada hari libur nasional pada pukul 18.30.
- b. Peramalan pemakaian beban listrik di Jawa Timur dengan metode *Time Series Regression* menggunakan data *in-sample* 1 tahun menghasilkan RMSE sebesar 156,7925 dimana residualnya tidak *white noise* dan tidak berdistribusi normal. Model *Time Series Regression* dengan menambahkan efek variasi kalender dan hari libur nasional dapat memperbaiki hasil ramalan dengan nilai RMSE sebesar 105,5293. Sedangkan, pada metode *Double Seasonal ARIMA* tanpa proses seleksi variabel menghasilkan nilai RMSE sebesar 156,5790 dengan residual yang sudah *white noise* tetapi tidak berdistribusi normal.
- 2.a. Peramalan pemakaian beban listrik di Jawa Timur dengan proses seleksi variabel menggunakan *Random Forest* pada model *Time Series Regression* diperoleh hasil nilai RMSE terbaik ketika menggunakan variabel input dari *Random Forest* tahap 2 (*Variabel selection for interpretation*). Nilai

RMSE sebesar 158,3580 dengan residual yang tidak *white noise* dan tidak berdistribusi normal. Sedangkan pada model *Double Seasonal ARIMA* menghasilkan RMSE sebesar 149,0967 dengan residual yang tidak *white noise* dan tidak berdistribusi normal.

- b. Peramalan pemakaian beban listrik di Jawa Timur dengan proses seleksi variabel menggunakan metode *Stepwise* pada model *Time Series Regression* diperoleh hasil nilai RMSE sebesar 105,3394 dengan residual yang tidak *white noise* dan tidak berdistribusi normal. Penambahan lag Y_t sebagai variabel prediktor mampu menghasilkan residual yang hampir mendekati *white noise*. Namun, hasil peramalannya tidak lebih baik dibanding dengan model *Time Series Regression* yang tidak melibatkan lag Y_t . Sedangkan pada model *Double Seasonal ARIMA* menghasilkan RMSE sebesar 149,7954 dengan residual yang tidak *white noise* dan tidak berdistribusi normal.
- c. Hasil peramalan pemakaian beban listrik di Jawa Timur menggunakan *Time Series Regression* dengan seleksi variabel menggunakan metode *Stepwise* menghasilkan nilai RMSE terkecil. Sedangkan pada model *Double Seasonal ARIMA*, hasil peramalan terbaik menggunakan seleksi variabel dengan *Random Forest*.
- d. Pada model *Time Series Regression* dengan seleksi variabel menggunakan *Random Forest* tidak menghasilkan ramalan yang baik. Hal ini diduga karena variabel prediktor yang digunakan berupa kategori sehingga ketepatan dalam membangun *tree* rendah.
- e. Berdasarkan *benchmark* yang telah ditetapkan oleh PT PLN (Persero), yaitu kesalahan maksimum peramalan sebesar 2%. Maka, model *Double Seasonal ARIMA* dengan pemilihan input menggunakan *Random Forest* baik untuk meramalkan pemakaian beban listrik di Jawa Timur hingga 2 hari kedepan. Sedangkan model *Time Series Regression* dengan pemilihan input menggunakan *Stepwise* baik untuk meramalkan kurang dari 1 hari kedepan.

5.2 Saran

Berdasarkan hasil analisis yang telah dilakukan, maka rekomendasi bagi PT PLN (Persero) di wilayah Jawa Timur dalam meramalkan pemakaian beban listrik sebaiknya menggunakan metode *Time Series Regression* dengan pemilihan input menggunakan metode *Stepwise*. Metode tersebut direkomendasikan karena menghasilkan peramalan yang lebih baik dibandingkan metode lain yang digunakan pada penelitian ini. Selain itu, penelitian ini tentunya memiliki beberapa kekurangan sehingga saran untuk penelitian selanjutnya yaitu sebagai berikut.

1. Perlu diperhatikan banyaknya observasi yang digunakan ketika melakukan seleksi variabel dengan *Random Forest*, karena *package* VSURF yang digunakan pada *software* R tidak bisa mengcover data dengan observasi yang terlalu banyak. Berdasarkan hasil penelitian ini diduga bahwa *package* VSURF lebih terfokus pada data dengan jumlah variabel yang banyak.
2. Pada pemodelan dengan *Time Series Regression* sebaiknya dilakukan pemodelan terhadap residualnya agar menghasilkan residual yang *white noise*. Selain itu, pada proses seleksi variabel baik menggunakan metode *Random Forest* maupun *Stepwise* perlu ditambah lag Y_t yang lebih banyak agar menghasilkan residual yang *white noise* serta ramalan yang lebih baik.
3. Pada pemodelan dengan *Double Seasonal ARIMA* sebaiknya dilakukan pemodelan terhadap adanya data *outlier* agar menghasilkan residual yang *white noise* dan berdistribusi normal, serta menghasilkan peramalan yang lebih baik.

DAFTAR PUSTAKA

- Bhaskaran, K., Gasparrini, A., Hajat, S., Smeeth, L., & Armstrong, B. (2013). Time Series Regression Studies in Environmental Epidemiology. *International Journal of Epidemiology*, **42** (4), 1187-1195.
- Bozdogan, H. 2000. Akaike's Information Criterion and Recent Developments in Information Complexity. *Journal of Mathematical Psychology*, **44**, 62-91.
- Breiman, L. (2001). Random Forest. *Machine Learning*, **45** (2), 5-32.
- Cryer, J. D., & Chan, K. S. (2008). *Time Series Analysis With Application in R*. New York: Springer Science.
- Daniel, W. W. 1989. *Statistik Non Parametrik Terapan*. Diterjemahkan oleh Alex Tri Kantjono W. Jakarta : PT. Gramedia.
- Draper, N. R., & Smith, H. (1992). *Analisis Regresi Terapan*. Jakarta : PT. Gramedia Pustaka Utama.
- Engle, R. F. (1982).Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, **50**, 987–1007.
- Geneur, R., Poggi, J. M., & Malot, C. T. (2015). VSURF : An R Package for Variable Selection Using Random Forest. *R Journal*, **7** (2).
- Hajat, S., Chalabi, Z., Wilkinson, P., Erens, B., Jones, L., & Mays, N. (2015). Public Health Vulnerability to Wintertime Weather : Time-Series-Regression and Episode Analysis of National Mortality and Morbidity Databases to Inform the Cold Weather Plan for England. *Public Health*, **137**, 26-43.
- Imai, C., Armstrong, B., Chalabi, Z., Mangtani, M., & Hashizume, M. (2015). Time Series Regression Model for Infectious Disease and Weather. *Environmental Research*, **142**, 319-327.
- Istalo, J. (2001). *Basic of Statistics*. Tampere : University of Tampere.

- Khair, A. (2011). *Peramalan Beban Listrik Jangka Pendek Menggunakan Kombinasi Metode Autoregressive Integrated Moving Average (ARIMA) dengan Regresi Linear antara Suhu dan Daya Listrik*. Tugas Akhir S1: Jurusan Teknik Elektro, Universitas Indonesia.
- Klinkenberg, R. (2005). Meta Learning, Model Selection, and Example Selection in Machine Learning Domains with Concept Drift. *LWA*, 164-171.
- Kocev, D., Dzeroski, S., White, M. D., Newell, G. R., & Griffioen, P. (2009). Using Single- and Multi-Target Regression Trees and Ensembles To Model A Compound Index of Vegetation Condition. *Ecological Modelling*, **220**, 1159–1168.
- Komalasari, W. B. (2007). Metode Pohon Regresi untuk Eksploratori Data dengan Peubah yang Banyak dan Kompleks. *Informatika Pertanian*, **16** (1).
- Ljung, G. M. & Box, G. E. P. (1978). On a Measure of Lack of Fit in Time Series Models. *Biometrika*, **65**, 297-303.
- Mkhonza, G. (2013). Technical Guidance Material Electrical Load Analysis. *Civil Aviation Authory*, **1** (5), 2-3.
- Mohamed, N., Ahmad, M.H., Suhartono, & Ismail, Z. (2011). Improving Short Term Load Forecasting Using Double Seasonal ARIMA Model. *World Applied Science Journal*, **15** (2), 223-231.
- Nababan, T. (2008). *Perintaan Eenergi Listrik Rumah Tangga (Strudi Kasus pada Pengguna Kelompok Rumah Tangga Listrik PT. PLN (Persero) di Kota Medan)*. Disertasi S3 : Jurusan Ilmu Ekonomi, Universitas Diponegoro.
- Ramasubramanian, V. (2007). *Time-Series Analysis, Modelling And Forecasting Using SAS Software. Technical Report*. New Delhi: Indian Agricultural Statistics Research Institute.
- Rawlings, J. O., Pantula, S. G., & Dickey, D. A. (1998). *Applied Regression Analysis : A Research Tool, Second Edition*. New York : Springer-Verlag.

- Soares, L. J., & Medeiros, M. C. (2008). Modeling and Forecasting Short-Term Electricity Load: A Comparison Methods with an application to Brazilian Data. *International Journal of Forecasting*, **24**, 630-644.
- Suhartono, Lee, M. H., & Prastyo, D. D. (2015). "Two levels ARIMAX and Regression Models for Forecasting Time Series Data with Calendar Variation Effects", AIP Conference Proceedings, 1691, 050026.
- Sunaryo, S., Suhartono, & Endharta, A. J. (2011). Double Seasonal Recurrent Neural Networks for Forecasting Short Term Electricity Load Demand in Indonesia. *Recurrent Neural Networks for Temporal Data Processing*, Prof. Hubert Cardot (Ed.). InTech.
- Triwulan, Y., Hariyanto, N., & Anwari, S. (2013). Peramalan Beban Puncak Listrik Jangka Pendek Menggunakan Metode Jaringan Syaraf Tiruan. *Jurnal Reka Elkomika*, **1** (4), 340-344.
- Wei, W. W. S. (2006). *Time Series Analysis Univariate and Multivariate Methods*. New York : Pearson Education, Inc.
- Wulansari, R., Suryanto, E., Ferawati, K., Andalita, I., & Suhartono. (2014). Penerapan *Time Series Regression with Calendar Variation Effect* pada Data *Netflow* Uang Kartal Bank Indonesia Sebagai Solusi Kontrol Likuiditas Perbankan di Indonesia. *Statistika*, **14** (2), 59-68.
- Xie, Y., Li, X., Ngai, E.W.T., & Ying, W. (2009). Customer Churn Prediction Using Improved Balanced Random Forests. *Expert Systems with Applications*, **36**, 5445–5449.
- Zhang, G., Li, H., & Fang, B. (2009). Discriminating Acidic and Alkaline Enzymes using a Random Forest Model with Secondary Structure Amino Acid Composition. *Process Biochemistry*, **44**, 654-660.

LAMPIRAN

Lampiran 1. Hasil Pengujian Parsial Model *Time Series Regression*.

<i>Predictor</i>	<i>Coef</i>	<i>SE Coef</i>	<i>T</i>	<i>p-value</i>
t	0,002274	0,000418	5,44	0,000
D1	3455,92	46,17	74,85	0,000
D2	3415,16	46,17	73,97	0,000
D3	3375,06	46,17	73,10	0,000
D4	3338,46	46,17	72,31	0,000
D5	3308,25	46,17	71,66	0,000
D6	3288,72	46,17	71,23	0,000
D7	3301,31	46,17	71,51	0,000
D8	3354,94	46,17	72,67	0,000
D9	3453,94	46,17	74,81	0,000
D10	3542,85	46,17	76,74	0,000
D11	3507,27	46,17	75,97	0,000
D12	3372,61	46,17	73,05	0,000
D13	3264,91	46,17	70,72	0,000
D14	3249,58	46,17	70,38	0,000
D15	3430,98	46,17	74,31	0,000
D16	3587,32	46,17	77,70	0,000
D17	3757,26	46,17	81,38	0,000
D18	3828,32	46,17	82,92	0,000
D19	3888,11	46,17	84,21	0,000
D20	3951,81	46,17	85,59	0,000
D21	3996,47	46,17	86,56	0,000
D22	4015,22	47,01	85,42	0,000
D23	3964,31	47,01	84,33	0,000
D24	3824,34	47,01	81,36	0,000
D25	3827,26	47,01	81,42	0,000
D26	3958,86	47,01	84,22	0,000

Lampiran 1. Hasil Pengujian Parsial Model *Time Series Regression* (lanjutan).

<i>Predictor</i>	<i>Coef</i>	<i>SE Coef</i>	<i>T</i>	<i>p-value</i>
D27	4090,43	46,17	88,60	0,000
D28	4080,32	46,17	88,38	0,000
D29	4051,33	46,17	87,75	0,000
D30	4009,96	46,17	86,85	0,000
D31	4001,8	46,17	86,68	0,000
D32	3956,52	46,17	85,70	0,000
D33	3955,25	46,17	85,67	0,000
D34	4028,6	46,17	87,26	0,000
D35	4316,11	46,17	93,48	0,000
D36	4474,37	46,17	96,91	0,000
D37	4487,34	46,17	97,19	0,000
D38	4459,93	46,17	96,60	0,000
D39	4456,61	46,17	96,53	0,000
D40	4427,28	46,17	95,89	0,000
D41	4356,84	46,17	94,37	0,000
D42	4236,03	46,17	91,75	0,000
D43	4062,79	46,17	88,00	0,000
D44	3912,33	46,17	84,74	0,000
D45	3851,44	46,17	83,42	0,000
D46	3738,73	46,17	80,98	0,000
D47	3655,57	46,17	79,18	0,000
D48	3579,48	39,11	91,52	0,000
H1	250,27	42,93	5,83	0,000
H2	377,51	42,93	8,79	0,000
H3	343,93	42,93	8,01	0,000
H4	347,58	42,92	8,10	0,000
H5	339,88	42,95	7,91	0,000
H6	132,58	55,07	2,41	0,016

Lampiran 1. Hasil Pengujian Parsial Model *Time Series Regression* (lanjutan).

<i>Predictor</i>	<i>Coef</i>	<i>SE Coef</i>	<i>T</i>	<i>p-value</i>
J1	-27,04	43,69	-0,62	0,536
J2	-168,27	43,69	-3,85	0,000
J3	-221,73	43,69	-5,08	0,000
J4	-192,07	43,69	-4,40	0,000
J5	-88,28	43,69	-2,02	0,043
S1	231,52	60,29	3,84	0,000
S2	237,78	60,29	3,94	0,000
S3	238,33	60,29	3,95	0,000
S4	235,55	60,29	3,91	0,000
S5	243,46	60,29	4,04	0,000
S6	226,79	60,29	3,76	0,000
S7	220,54	60,29	3,66	0,000
S8	217,2	60,29	3,60	0,000
S9	213,3	60,29	3,54	0,000
S10	198,34	60,29	3,29	0,001
S11	183,86	60,29	3,05	0,002
S12	168,9	60,29	2,80	0,005
S13	129,13	60,29	2,14	0,032
S14	85,91	60,29	1,43	0,154
S15	21,48	60,29	0,36	0,722
S16	-29,48	60,29	-0,49	0,625
S17	-63,93	60,29	-1,06	0,289
S18	-69,95	60,29	-1,16	0,246
S19	-81,97	60,29	-1,36	0,174
S20	-84,48	60,29	-1,40	0,161
S21	-81,33	60,29	-1,35	0,177
S22	-82,94	60,93	-1,36	0,173
S23	-53,79	60,93	-0,88	0,377

Lampiran 1. Hasil Pengujian Parsial Model *Time Series Regression* (lanjutan).

<i>Predictor</i>	<i>Coef</i>	<i>SE Coef</i>	<i>T</i>	<i>p-value</i>
S24	-16,42	60,93	-0,27	0,788
S25	-46,83	60,93	-0,77	0,442
S26	-140,93	60,93	-2,31	0,021
S27	-209,62	60,29	-3,48	0,001
S28	-230,16	60,29	-3,82	0,000
S29	-237,13	60,29	-3,93	0,000
S30	-240,47	60,29	-3,99	0,000
S31	-244,5	60,29	-4,06	0,000
S32	-213,47	60,29	-3,54	0,000
S33	-167,51	60,29	-2,78	0,005
S34	-122,54	60,29	-2,03	0,042
S35	-69,79	60,29	-1,16	0,247
S36	-28,89	60,29	-0,48	0,632
S37	-16,32	60,29	-0,27	0,787
S38	-18,88	60,29	-0,31	0,754
S39	-41,9	60,29	-0,70	0,487
S40	-44,81	60,29	-0,74	0,457
S41	-31,1	60,29	-0,52	0,606
S42	-23,21	60,29	-0,39	0,700
S43	-9,61	60,29	-0,16	0,873
S44	-19,48	60,29	-0,32	0,747
S45	-27,35	60,29	-0,45	0,650
S46	-11,1	60,29	-0,18	0,854
S47	-7,07	60,29	-0,12	0,907
M1	192,06	60,29	3,19	0,001
M2	188,43	60,29	3,13	0,002
M3	182,49	60,29	3,03	0,002


Lampiran 1. Hasil Pengujian Parsial Model *Time Series Regression* (lanjutan).

<i>Predictor</i>	<i>Coef</i>	<i>SE Coef</i>	<i>T</i>	<i>p-value</i>
M4	182,63	60,29	3,03	0,002
M5	177,87	60,29	2,95	0,003
M6	182,5	60,29	3,03	0,002
M7	166,06	60,29	2,75	0,006
M8	154,52	60,29	2,56	0,010
M9	114,08	60,29	1,89	0,058
M10	69,16	60,29	1,15	0,251
M11	40,14	60,29	0,67	0,506
M12	28,83	60,29	0,48	0,632
M13	35,55	60,29	0,59	0,555
M14	-21,52	60,29	-0,36	0,721
M15	-192,54	60,29	-3,19	0,001
M16	-328,2	60,29	-5,44	0,000
M17	-461,23	60,29	-7,65	0,000
M18	-516,01	60,29	-8,56	0,000
M19	-546,35	60,29	-9,06	0,000
M20	-573,62	60,29	-9,51	0,000
M21	-587,47	60,29	-9,74	0,000
M22	-596,31	60,93	-9,79	0,000
M23	-551,87	60,93	-9,06	0,000
M24	-436,1	60,93	-7,16	0,000
M25	-437,68	60,93	-7,18	0,000
M26	-555,42	60,93	-9,12	0,000
M27	-655,44	60,29	-10,87	0,000
M28	-656,34	60,29	-10,89	0,000
M29	-634,61	60,29	-10,53	0,000
M30	-596,49	60,29	-9,89	0,000

Lampiran 1. Hasil Pengujian Parsial Model *Time Series Regression* (lanjutan).

<i>Predictor</i>	<i>Coef</i>	<i>SE Coef</i>	<i>T</i>	<i>p-value</i>
M31	-552,05	60,29	-9,16	0,000
M32	-463,83	60,29	-7,69	0,000
M33	-383,56	60,29	-6,36	0,000
M34	-298,21	60,29	-4,95	0,000
M35	-210,6	60,29	-3,49	0,000
M36	-145,07	60,29	-2,41	0,016
M37	-116,91	60,29	-1,94	0,052
M38	-104,92	60,29	-1,74	0,082
M39	-104,33	60,29	-1,73	0,084
M40	-91,83	60,29	-1,52	0,128
M41	-72,17	60,29	-1,20	0,231
M42	-59,3	60,29	-0,98	0,325
M43	-50,08	60,29	-0,83	0,406
M44	-46,77	60,29	-0,78	0,438
M45	-48,2	60,29	-0,80	0,424
M46	-22,06	60,29	-0,37	0,714
M47	-18,1	60,29	-0,30	0,764

Lampiran 2. Hasil Uji Kolmogorov-Smirnov Residual Model *Time Series Regression*.



Lampiran 3. *Output Time Series Regression* dengan Variasi Kalender.

The regression equation is

$$\begin{aligned}
 Y(t) = & 0,00690 t + 3424 D1 + 3383 D2 + 3343 D3 + 3307 D4 \\
 & + 3276 D5 + 3257 D6 + 3269 D7 + 3323 D8 + 3422 D9 \\
 & + 3511 D10 + 3475 D11 + 3341 D12 + 3233 D13 + \\
 & 3218 D14 + 3399 D15 + 3555 D16 + 3725 D17 + 3796 \\
 & D18 + 3856 D19 + 3920 D20 + 3964 D21 + 3983 D22 + \\
 & 3932 D23 + 3792 D24 + 3795 D25 + 3927 D26 + 4058 \\
 & D27 + 4048 D28 + 4019 D29 + 3978 D30 + 3970 D31 + \\
 & 3924 D32 + 3923 D33 + 3997 D34 + 4284 D35 + 4442 \\
 & D36 + 4455 D37 + 4428 D38 + 4425 D39 + 4395 D40 + \\
 & 4325 D41 + 4204 D42 + 4031 D43 + 3880 D44 + 3819 \\
 & D45 + 3707 D46 + 3623 D47 + 3547 D48 + 262 H1 + \\
 & 395 H2 + 366 H3 + 370 H4 + 361 H5 + 149 H6 - 27,0 \\
 & J1 - 168 J2 - 222 J3 - 192 J4 - 88,3 J5 + 232 S1 \\
 & + 238 S2 + 238 S3 + 236 S4 + 243 S5 + 227 S6 + \\
 & 221 S7 + 217 S8 + 213 S9 + 198 S10 + 184 S11 + \\
 & 169 S12 + 129 S13 + 85,9 S14 + 21,5 S15 - 29,5 \\
 & S16 - 63,9 S17 - 69,9 S18 - 82,0 S19 - 84,5 S20 \\
 & - 81,3 S21 - 82,9 S22 - 53,8 S23 - 16,4 S24 - \\
 & 46,8 S25 - 141 S26 - 210 S27 - 230 S28 - 237 S29 \\
 & - 240 S30 - 245 S31 - 213 S32 - 168 S33 - 123 \\
 & S34 - 69,8 S35 - 28,9 S36 - 16,3 S37 - 18,9 S38 - \\
 & 41,9 S39 - 44,8 S40 - 31,1 S41 - 23,2 S42 - 9,6 \\
 & S43 - 19,5 S44 - 27,4 S45 - 11,1 S46 - 7,1 S47 + \\
 & 192 M1 + 188 M2 + 182 M3 + 183 M4 + 178 M5 + 182 \\
 & M6 + 166 M7 + 155 M8 + 114 M9 + 69,2 M10 + 40,1 \\
 & M11 + 28,8 M12 + 35,6 M13 - 21,5 M14 - 193 M15 - \\
 & 328 M16 - 461 M17 - 516 M18 - 546 M19 - 574 M20 - \\
 & 587 M21 - 596 M22 - 552 M23 - 436 M24 - 438 M25 - \\
 & 555 M26 - 655 M27 - 656 M28 - 635 M29 - 596 M30 - \\
 & 552 M31 - 464 M32 - 384 M33 - 298 M34 - 211 M35 - \\
 & 145 M36 - 117 M37 - 105 M38 - 104 M39 - 91,8 M40 \\
 & - 72,2 M41 - 59,3 M42 - 50,1 M43 - 46,8 M44 - \\
 & 48,2 M45 - 22,1 M46 - 18,1 M47 - 34,9 P1 - 295 \\
 & It-3 - 883 It-2 - 1175 It-1 - 1451 It - 1501 It+1 \\
 & - 1418 It+2 - 123 It+3
 \end{aligned}$$

Lampiran 3. *Output Time Series Regression* dengan Variasi Kalender (Lanjutan).

Predictor	Coef	SE Coef	T	P
Noconstant				
t	0,0068969	0,0003537	19,50	0,000
D1	3423,99	37,61	91,04	0,000
D2	3383,23	37,61	89,96	0,000
D3	3343,12	37,61	88,89	0,000
D4	3306,52	37,61	87,92	0,000
D5	3276,31	37,61	87,12	0,000
D6	3256,77	37,61	86,60	0,000
D7	3269,35	37,61	86,93	0,000
D8	3322,98	37,61	88,36	0,000
D9	3421,98	37,61	90,99	0,000
D10	3510,88	37,61	93,35	0,000
D11	3475,29	37,61	92,41	0,000
D12	3340,63	37,61	88,83	0,000
D13	3232,92	37,61	85,96	0,000
D14	3217,59	37,61	85,55	0,000
D15	3398,99	37,61	90,38	0,000
D16	3555,32	37,61	94,53	0,000
D17	3725,25	37,61	99,05	0,000
D18	3796,31	37,61	100,94	0,000
D19	3856,10	37,61	102,53	0,000
D20	3919,80	37,61	104,23	0,000
D21	3964,45	37,61	105,41	0,000
D22	3983,20	38,29	104,02	0,000
D23	3932,28	38,29	102,69	0,000
D24	3792,31	38,29	99,04	0,000
D25	3795,22	38,29	99,11	0,000
D26	3926,81	38,29	102,55	0,000
D27	4058,38	37,61	107,91	0,000
D28	4048,26	37,61	107,64	0,000
D29	4019,27	37,61	106,87	0,000
D30	3977,90	37,61	105,77	0,000
D31	3969,73	37,61	105,55	0,000
D32	3924,45	37,61	104,35	0,000
D33	3923,17	37,61	104,31	0,000
D34	3996,51	37,61	106,26	0,000
D35	4284,02	37,61	113,91	0,000
D36	4442,28	37,61	118,12	0,000

Lampiran 3. *Output Time Series Regression* dengan Variasi Kalender (Lanjutan).

D37	4455,24	37,61	118,46	0,000
D38	4427,83	37,61	117,73	0,000
D39	4424,51	37,61	117,64	0,000
D40	4395,17	37,61	116,86	0,000
D41	4324,73	37,61	114,99	0,000
D42	4203,91	37,61	111,78	0,000
D43	4030,67	37,61	107,17	0,000
D44	3880,20	37,61	103,17	0,000
D45	3819,31	37,61	101,55	0,000
D46	3706,59	37,61	98,55	0,000
D47	3623,43	37,61	96,34	0,000
D48	3547,33	31,86	111,33	0,000
H1	262,03	34,97	7,49	0,000
H2	394,67	34,97	11,28	0,000
H3	365,50	34,97	10,45	0,000
H4	370,08	34,97	10,58	0,000
H5	360,58	34,99	10,30	0,000
H6	148,73	44,86	3,32	0,001
J1	-27,04	35,58	-0,76	0,447
J2	-168,27	35,58	-4,73	0,000
J3	-221,73	35,58	-6,23	0,000
J4	-192,07	35,58	-5,40	0,000
J5	-88,28	35,58	-2,48	0,013
S1	231,52	49,10	4,72	0,000
S2	237,78	49,10	4,84	0,000
S3	238,33	49,10	4,85	0,000
S4	235,55	49,10	4,80	0,000
S5	243,46	49,10	4,96	0,000
S6	226,79	49,10	4,62	0,000
S7	220,54	49,10	4,49	0,000
S8	217,20	49,10	4,42	0,000
S9	213,30	49,10	4,34	0,000
S10	198,34	49,10	4,04	0,000
S11	183,86	49,10	3,74	0,000
S12	168,90	49,10	3,44	0,001
S13	129,13	49,10	2,63	0,009
S14	85,91	49,10	1,75	0,080
S15	21,48	49,10	0,44	0,662
S16	-29,48	49,10	-0,60	0,548

Lampiran 3. *Output Time Series Regression* dengan Variasi Kalender (Lanjutan).

S17	-63,93	49,10	-1,30	0,193
S18	-69,95	49,10	-1,42	0,154
S19	-81,97	49,10	-1,67	0,095
S20	-84,48	49,10	-1,72	0,085
S21	-81,33	49,10	-1,66	0,098
S22	-82,94	49,63	-1,67	0,095
S23	-53,79	49,63	-1,08	0,278
S24	-16,42	49,63	-0,33	0,741
S25	-46,83	49,63	-0,94	0,345
S26	-140,93	49,63	-2,84	0,005
S27	-209,62	49,10	-4,27	0,000
S28	-230,16	49,10	-4,69	0,000
S29	-237,13	49,10	-4,83	0,000
S30	-240,47	49,10	-4,90	0,000
S31	-244,50	49,10	-4,98	0,000
S32	-213,47	49,10	-4,35	0,000
S33	-167,51	49,10	-3,41	0,001
S34	-122,54	49,10	-2,50	0,013
S35	-69,79	49,10	-1,42	0,155
S36	-28,89	49,10	-0,59	0,556
S37	-16,32	49,10	-0,33	0,740
S38	-18,88	49,10	-0,38	0,701
S39	-41,90	49,10	-0,85	0,393
S40	-44,81	49,10	-0,91	0,361
S41	-31,10	49,10	-0,63	0,526
S42	-23,21	49,10	-0,47	0,636
S43	-9,61	49,10	-0,20	0,845
S44	-19,48	49,10	-0,40	0,692
S45	-27,35	49,10	-0,56	0,578
S46	-11,10	49,10	-0,23	0,821
S47	-7,07	49,10	-0,14	0,885
M1	192,06	49,10	3,91	0,000
M2	188,43	49,10	3,84	0,000
M3	182,49	49,10	3,72	0,000
M4	182,63	49,10	3,72	0,000
M5	177,87	49,10	3,62	0,000
M6	182,50	49,10	3,72	0,000
M7	166,06	49,10	3,38	0,001
M8	154,52	49,10	3,15	0,002

Lampiran 3. *Output Time Series Regression* dengan Variasi Kalender (Lanjutan).

M9	114,08	49,10	2,32	0,020
M10	69,16	49,10	1,41	0,159
M11	40,14	49,10	0,82	0,414
M12	28,83	49,10	0,59	0,557
M13	35,55	49,10	0,72	0,469
M14	-21,52	49,10	-0,44	0,661
M15	-192,54	49,10	-3,92	0,000
M16	-328,20	49,10	-6,68	0,000
M17	-461,23	49,10	-9,39	0,000
M18	-516,01	49,10	-10,51	0,000
M19	-546,35	49,10	-11,13	0,000
M20	-573,62	49,10	-11,68	0,000
M21	-587,47	49,10	-11,96	0,000
M22	-596,31	49,63	-12,02	0,000
M23	-551,87	49,63	-11,12	0,000
M24	-436,10	49,63	-8,79	0,000
M25	-437,68	49,63	-8,82	0,000
M26	-555,42	49,63	-11,19	0,000
M27	-655,44	49,10	-13,35	0,000
M28	-656,34	49,10	-13,37	0,000
M29	-634,61	49,10	-12,92	0,000
M30	-596,49	49,10	-12,15	0,000
M31	-552,05	49,10	-11,24	0,000
M32	-463,83	49,10	-9,45	0,000
M33	-383,56	49,10	-7,81	0,000
M34	-298,21	49,10	-6,07	0,000
M35	-210,60	49,10	-4,29	0,000
M36	-145,07	49,10	-2,95	0,003
M37	-116,91	49,10	-2,38	0,017
M38	-104,92	49,10	-2,14	0,033
M39	-104,33	49,10	-2,12	0,034
M40	-91,83	49,10	-1,87	0,061
M41	-72,17	49,10	-1,47	0,142
M42	-59,30	49,10	-1,21	0,227
M43	-50,08	49,10	-1,02	0,308
M44	-46,77	49,10	-0,95	0,341
M45	-48,20	49,10	-0,98	0,326
M46	-22,06	49,10	-0,45	0,653
M47	-18,10	49,10	-0,37	0,712

Lampiran 3. *Output Time Series Regression dengan Variasi Kalender (Lanjutan).*


P1	-34,929	6,805	-5,13	0,000
It-3	-294,63	33,91	-8,69	0,000
It-2	-882,78	33,88	-26,05	0,000
It-1	-1174,99	33,88	-34,68	0,000
It	-1450,98	33,39	-43,46	0,000
It+1	-1501,19	33,39	-44,96	0,000
It+2	-1417,62	33,39	-42,46	0,000
It+3	-1123,01	33,40	-33,63	0,000

S = 228,699

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	162	2,94079E+11	1815305357	34707,22	0,000
Residual Error	17406	910392726	52303		
Total	17568	2,94990E+11			

Lampiran 4. *Normality Test dan ACF Residual Model Time Series Regression dengan Variasi Kalender.*



**Lampiran 5. *Output Time Series Regression* dengan Variasi
Kalender dan Hari Libur Nasional.**

The regression equation is

$$\begin{aligned}
 Y(t) = & 0,00562 \, t + 3439 \, D1 + 3398 \, D2 + 3358 \, D3 + 3321 \, D4 + \\
 & 3291 \, D5 + 3272 \, D6 + 3284 \, D7 + 3338 \, D8 + 3437 \, D9 + 3526 \\
 & D10 + 3490 \, D11 + 3355 \, D12 + 3248 \, D13 + 3232 \, D14 + 3414 \\
 & D15 + 3570 \, D16 + 3740 \, D17 + 3811 \, D18 + 3871 \, D19 + 3935 \\
 & D20 + 3979 \, D21 + 3998 \, D22 + 3947 \, D23 + 3807 \, D24 + 3810 \\
 & D25 + 3942 \, D26 + 4073 \, D27 + 4063 \, D28 + 4034 \, D29 + 3993 \\
 & D30 + 3985 \, D31 + 3939 \, D32 + 3938 \, D33 + 4011 \, D34 + 4299 \\
 & D35 + 4457 \, D36 + 4470 \, D37 + 4443 \, D38 + 4439 \, D39 + 4410 \\
 & D40 + 4340 \, D41 + 4219 \, D42 + 4046 \, D43 + 3895 \, D44 + 3834 \\
 & D45 + 3721 \, D46 + 3638 \, D47 + 3562 \, D48 + 291 \, H1 + 392 \, H2 \\
 & + 378 \, H3 + 406 \, H4 + 415 \, H5 + 146 \, H6 - 27,0 \, J1 - 168 \, J2 \\
 & - 222 \, J3 - 192 \, J4 - 88,3 \, J5 + 232 \, S1 + 238 \, S2 + 238 \, S3 \\
 & + 236 \, S4 + 243 \, S5 + 227 \, S6 + 221 \, S7 + 217 \, S8 + 213 \, S9 \\
 & + 198 \, S10 + 184 \, S11 + 169 \, S12 + 129 \, S13 + 85,9 \, S14 + \\
 & 21,5 \, S15 - 29,5 \, S16 - 63,9 \, S17 - 69,9 \, S18 - 82,0 \, S19 - \\
 & 84,5 \, S20 - 81,3 \, S21 - 82,9 \, S22 - 53,8 \, S23 - 16,4 \, S24 - \\
 & 46,8 \, S25 - 141 \, S26 - 210 \, S27 - 230 \, S28 - 237 \, S29 - 240 \\
 & S30 - 245 \, S31 - 213 \, S32 - 168 \, S33 - 123 \, S34 - 69,8 \, S35 \\
 & - 28,9 \, S36 - 16,3 \, S37 - 18,9 \, S38 - 41,9 \, S39 - 44,8 \\
 & S40 - 31,1 \, S41 - 23,2 \, S42 - 9,6 \, S43 - 19,5 \, S44 - 27,4 \\
 & S45 - 11,1 \, S46 - 7,1 \, S47 + 192 \, M1 + 188 \, M2 + 182 \, M3 + \\
 & 183 \, M4 + 178 \, M5 + 182 \, M6 + 166 \, M7 + 155 \, M8 + 114 \, M9 + \\
 & 69,2 \, M10 + 40,1 \, M11 + 28,8 \, M12 + 35,6 \, M13 - 21,5 \, M14 - \\
 & 193 \, M15 - 328 \, M16 - 461 \, M17 - 516 \, M18 - 546 \, M19 - 574 \\
 & M20 - 587 \, M21 - 596 \, M22 - 552 \, M23 - 436 \, M24 - 438 \, M25 \\
 & - 555 \, M26 - 655 \, M27 - 656 \, M28 - 635 \, M29 - 596 \, M30 - \\
 & 552 \, M31 - 464 \, M32 - 384 \, M33 - 298 \, M34 - 211 \, M35 - 145 \\
 & M36 - 117 \, M37 - 105 \, M38 - 104 \, M39 - 91,8 \, M40 - 72,2 \\
 & M41 - 59,3 \, M42 - 50,1 \, M43 - 46,8 \, M44 - 48,2 \, M45 - 22,1 \\
 & M46 - 18,1 \, M47 - 52,0 \, P1 - 275 \, It-3 - 892 \, It-2 - 1153 \\
 & It-1 - 1460 \, It - 1534 \, It+1 - 1469 \, It+2 - 1118 \, It+3 - \\
 & 886 \, N1 - 426 \, N2 - 679 \, N3 - 813 \, N4 - 1133 \, N5 - 777 \, N6 - \\
 & 307 \, N7 - 412 \, N8 - 429 \, N9 - 610 \, N10 - 140 \, N11 - 823 \\
 & N12
 \end{aligned}$$

**Lampiran 5. *Output Time Series Regression* dengan Variasi
Kalender dan Hari Libur Nasional (Lanjutan).**

Predictor	Coef	SE Coef	T	P
Noconstant				
t	0,0056160	0,0003072	18,28	0,000
D1	3438,78	32,10	107,11	0,000
D2	3398,02	32,10	105,84	0,000
D3	3357,92	32,10	104,59	0,000
D4	3321,31	32,10	103,45	0,000
D5	3291,10	32,10	102,51	0,000
D6	3271,56	32,10	101,90	0,000
D7	3284,15	32,10	102,30	0,000
D8	3337,77	32,10	103,97	0,000
D9	3436,78	32,10	107,05	0,000
D10	3525,68	32,10	109,82	0,000
D11	3490,09	32,10	108,71	0,000
D12	3355,43	32,10	104,52	0,000
D13	3247,73	32,10	101,16	0,000
D14	3232,40	32,10	100,68	0,000
D15	3413,80	32,10	106,33	0,000
D16	3570,13	32,10	111,20	0,000
D17	3740,07	32,10	116,50	0,000
D18	3811,12	32,10	118,71	0,000
D19	3870,91	32,10	120,57	0,000
D20	3934,61	32,10	122,56	0,000
D21	3979,27	32,10	123,95	0,000
D22	3998,01	32,69	122,31	0,000
D23	3947,10	32,69	120,75	0,000
D24	3807,13	32,69	116,47	0,000
D25	3810,04	32,69	116,56	0,000
D26	3941,63	32,69	120,59	0,000
D27	4073,21	32,10	126,87	0,000
D28	4063,09	32,10	126,56	0,000
D29	4034,10	32,10	125,65	0,000
D30	3992,73	32,10	124,36	0,000
D31	3984,56	32,10	124,11	0,000
D32	3939,28	32,11	122,70	0,000
D33	3938,00	32,11	122,66	0,000
D34	4011,35	32,11	124,94	0,000
D35	4298,86	32,11	133,90	0,000
D36	4457,11	32,11	138,83	0,000
D37	4470,08	32,11	139,23	0,000

**Lampiran 5. *Output Time Series Regression* dengan Variasi
Kalender dan Hari Libur Nasional (Lanjutan).**

D38	4442,67	32,11	138,38	0,000
D39	4439,35	32,11	138,28	0,000
D40	4410,01	32,11	137,36	0,000
D41	4339,57	32,11	135,17	0,000
D42	4218,75	32,11	131,40	0,000
D43	4045,51	32,11	126,01	0,000
D44	3895,04	32,11	121,32	0,000
D45	3834,16	32,11	119,42	0,000
D46	3721,44	32,11	115,91	0,000
D47	3638,28	32,11	113,32	0,000
D48	3562,18	27,20	130,96	0,000
H1	291,05	29,87	9,75	0,000
H2	392,38	29,86	13,14	0,000
H3	377,65	29,87	12,64	0,000
H4	406,02	29,87	13,59	0,000
H5	415,32	29,89	13,89	0,000
H6	146,25	38,29	3,82	0,000
J1	-27,04	30,37	-0,89	0,373
J2	-168,27	30,37	-5,54	0,000
J3	-221,73	30,37	-7,30	0,000
J4	-192,07	30,37	-6,32	0,000
J5	-88,28	30,37	-2,91	0,004
S1	231,52	41,91	5,52	0,000
S2	237,78	41,91	5,67	0,000
S3	238,33	41,91	5,69	0,000
S4	235,55	41,91	5,62	0,000
S5	243,46	41,91	5,81	0,000
S6	226,79	41,91	5,41	0,000
S7	220,54	41,91	5,26	0,000
S8	217,20	41,91	5,18	0,000
S9	213,30	41,91	5,09	0,000
S10	198,34	41,91	4,73	0,000
S11	183,86	41,91	4,39	0,000
S12	168,90	41,91	4,03	0,000
S13	129,13	41,91	3,08	0,002
S14	85,91	41,91	2,05	0,040
S15	21,48	41,91	0,51	0,608
S16	-29,48	41,91	-0,70	0,482

**Lampiran 5. *Output Time Series Regression* dengan Variasi
Kalender dan Hari Libur Nasional (Lanjutan).**

S17	-63,93	41,91	-1,53	0,127
S18	-69,95	41,91	-1,67	0,095
S19	-81,97	41,91	-1,96	0,050
S20	-84,48	41,91	-2,02	0,044
S21	-81,33	41,91	-1,94	0,052
S22	-82,94	42,36	-1,96	0,050
S23	-53,79	42,36	-1,27	0,204
S24	-16,42	42,36	-0,39	0,698
S25	-46,83	42,36	-1,11	0,269
S26	-140,93	42,36	-3,33	0,001
S27	-209,62	41,91	-5,00	0,000
S28	-230,16	41,91	-5,49	0,000
S29	-237,13	41,91	-5,66	0,000
S30	-240,47	41,91	-5,74	0,000
S31	-244,50	41,91	-5,83	0,000
S32	-213,47	41,91	-5,09	0,000
S33	-167,51	41,91	-4,00	0,000
S34	-122,54	41,91	-2,92	0,003
S35	-69,79	41,91	-1,67	0,096
S36	-28,89	41,91	-0,69	0,491
S37	-16,32	41,91	-0,39	0,697
S38	-18,88	41,91	-0,45	0,652
S39	-41,90	41,91	-1,00	0,317
S40	-44,81	41,91	-1,07	0,285
S41	-31,10	41,91	-0,74	0,458
S42	-23,21	41,91	-0,55	0,580
S43	-9,61	41,91	-0,23	0,819
S44	-19,48	41,91	-0,46	0,642
S45	-27,35	41,91	-0,65	0,514
S46	-11,10	41,91	-0,26	0,791
S47	-7,07	41,91	-0,17	0,866
M1	192,06	41,91	4,58	0,000
M2	188,43	41,91	4,50	0,000
M3	182,49	41,91	4,35	0,000
M4	182,63	41,91	4,36	0,000
M5	177,87	41,91	4,24	0,000
M6	182,50	41,91	4,35	0,000
M7	166,06	41,91	3,96	0,000

**Lampiran 5. *Output Time Series Regression* dengan Variasi
Kalender dan Hari Libur Nasional (Lanjutan).**

M8	154,52	41,91	3,69	0,000
M9	114,08	41,91	2,72	0,006
M10	69,16	41,91	1,65	0,099
M11	40,14	41,91	0,96	0,338
M12	28,83	41,91	0,69	0,491
M13	35,55	41,91	0,85	0,396
M14	-21,52	41,91	-0,51	0,608
M15	-192,54	41,91	-4,59	0,000
M16	-328,20	41,91	-7,83	0,000
M17	-461,23	41,91	-11,01	0,000
M18	-516,01	41,91	-12,31	0,000
M19	-546,35	41,91	-13,04	0,000
M20	-573,62	41,91	-13,69	0,000
M21	-587,47	41,91	-14,02	0,000
M22	-596,31	42,36	-14,08	0,000
M23	-551,87	42,36	-13,03	0,000
M24	-436,10	42,36	-10,30	0,000
M25	-437,68	42,36	-10,33	0,000
M26	-555,42	42,36	-13,11	0,000
M27	-655,44	41,91	-15,64	0,000
M28	-656,34	41,91	-15,66	0,000
M29	-634,61	41,91	-15,14	0,000
M30	-596,49	41,91	-14,23	0,000
M31	-552,05	41,91	-13,17	0,000
M32	-463,83	41,91	-11,07	0,000
M33	-383,56	41,91	-9,15	0,000
M34	-298,21	41,91	-7,12	0,000
M35	-210,60	41,91	-5,03	0,000
M36	-145,07	41,91	-3,46	0,001
M37	-116,91	41,91	-2,79	0,005
M38	-104,92	41,91	-2,50	0,012
M39	-104,33	41,91	-2,49	0,013
M40	-91,83	41,91	-2,19	0,028
M41	-72,17	41,91	-1,72	0,085
M42	-59,30	41,91	-1,42	0,157
M43	-50,08	41,91	-1,19	0,232
M44	-46,77	41,91	-1,12	0,264
M45	-48,20	41,91	-1,15	0,250
M46	-22,06	41,91	-0,53	0,599

**Lampiran 5. *Output Time Series Regression* dengan Variasi
Kalender dan Hari Libur Nasional (Lanjutan).**


M47	-18,10	41,91	-0,43	0,666
P1	-52,005	5,820	-8,94	0,000
It-3	-274,94	28,95	-9,50	0,000
It-2	-892,05	28,93	-30,83	0,000
It-1	-1152,89	28,92	-39,86	0,000
It	-1460,33	28,51	-51,23	0,000
It+1	-1534,28	28,51	-53,82	0,000
It+2	-1469,44	28,52	-51,53	0,000
It+3	-1117,54	28,51	-39,20	0,000
N1	-886,33	28,58	-31,01	0,000
N2	-426,22	28,56	-14,92	0,000
N3	-679,10	28,49	-23,83	0,000
N4	-813,47	28,50	-28,55	0,000
N5	-1132,78	28,49	-39,76	0,000
N6	-777,09	28,47	-27,30	0,000
N7	-306,83	28,46	-10,78	0,000
N8	-412,04	28,47	-14,47	0,000
N9	-428,97	28,47	-15,07	0,000
N10	-610,20	28,48	-21,43	0,000
N11	-140,13	28,52	-4,91	0,000
N12	-822,78	28,59	-28,78	0,000

S = 195,195

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	174	2,94327E+11	1691535223	44395,88	0,000
Residual Error	17394	662731808	38101		
Total	17568	2,94990E+11			

Lampiran 6. *Normality Test dan ACF Residual Model Time Series Regression dengan Variasi Kalender dan Hari Libur Nasional.*



Lampiran 7. *Output Time Series Regression Data 1 Bulan.*

The regression equation is

$$\begin{aligned}
 Y(t) = & -0,0092 t + 3568 D1 + 3521 D2 + 3490 D3 + 3448 D4 + \\
 & 3414 D5 + 3388 D6 + 3387 D7 + 3441 D8 + 3566 D9 + 3694 \\
 & D10 + 3658 D11 + 3494 D12 + 3352 D13 + 3348 D14 + 3536 \\
 & D15 + 3707 D16 + 3881 D17 + 3943 D18 + 4020 D19 + 4072 \\
 & D20 + 4123 D21 + 4136 D22 + 4076 D23 + 3929 D24 + 3942 \\
 & D25 + 4079 D26 + 4249 D27 + 4236 D28 + 4210 D29 + 4172 \\
 & D30 + 4137 D31 + 4071 D32 + 4067 D33 + 4145 D34 + 4517 \\
 & D35 + 4671 D36 + 4649 D37 + 4612 D38 + 4601 D39 + 4554 \\
 & D40 + 4482 D41 + 4360 D42 + 4200 D43 + 4067 D44 + 4006 \\
 & D45 + 3891 D46 + 3802 D47 + 3711 D48 + 142 H1 + 427 H2 \\
 & + 492 H3 + 485 H4 + 494 H5 + 172 H6 - 1 J1 - 148 J2 - \\
 & 208 J3 - 150 J4 - 59 J5 + 340 S1 + 363 S2 + 346 S3 + 353 \\
 & S4 + 365 S5 + 330 S6 + 340 S7 + 323 S8 + 313 S9 + 303 \\
 & S10 + 278 S11 + 300 S12 + 209 S13 + 176 S14 + 54 S15 + \\
 & 20 S16 - * S17 - 15 S18 - 34 S19 - 10 S20 - 0 S21 - 7 \\
 & S22 + 30 S23 + 93 S24 + 28 S25 - 76 S26 - 166 S27 - 231 \\
 & S28 - 238 S29 - 247 S30 - 244 S31 - 180 S32 - 127 S33 - \\
 & 57 S34 - 20 S35 - 4 S36 - 4 S37 + 1 S38 - 24 S39 - 33 \\
 & S40 - 18 S41 - 37 S42 - 13 S43 - 15 S44 - 22 S45 - 6 S46 \\
 & - 16 S47 + 266 M1 + 244 M2 + 254 M3 + 251 M4 + 246 M5 + \\
 & 250 M6 + 239 M7 + 216 M8 + 176 M9 + 106 M10 + 33 M11 + \\
 & 63 M12 + 69 M13 + 22 M14 - 160 M15 - 300 M16 - 434 M17 - \\
 & 484 M18 - 538 M19 - 580 M20 - 582 M21 - 571 M22 - 511 \\
 & M23 - 389 M24 - 370 M25 - 505 M26 - 673 M27 - 661 M28 \\
 & - 654 M29 - 621 M30 - 556 M31 - 470 M32 - 403 M33 - 331 \\
 & M34 - 250 M35 - 136 M36 - 125 M37 - 120 M38 - 103 M39 - \\
 & 112 M40 - 79 M41 - 52 M42 - 30 M43 - 42 M44 - 29 M45 - \\
 & 19 M46 - 17 M47
 \end{aligned}$$

**Lampiran 7. Output Time Series Regression Data 1 Bulan
(Lanjutan).**

Predictor	Coef	SE Coef	T	P
Noconstant				
t	-0,00915	0,01271	-0,72	0,471
D1	3567,9	116,1	30,72	0,000
D2	3521,2	116,1	30,32	0,000
D3	3490,2	116,1	30,05	0,000
D4	3448,3	116,1	29,69	0,000
D5	3414,4	116,1	29,40	0,000
D6	3388,3	116,1	29,17	0,000
D7	3386,9	116,1	29,16	0,000
D8	3441,0	116,1	29,63	0,000
D9	3565,9	116,1	30,70	0,000
D10	3694,0	116,2	31,80	0,000
D11	3658,2	116,2	31,50	0,000
D12	3493,8	116,2	30,08	0,000
D13	3352,0	116,2	28,86	0,000
D14	3348,2	116,2	28,83	0,000
D15	3536,0	116,2	30,44	0,000
D16	3707,1	116,2	31,91	0,000
D17	3881,3	116,2	33,41	0,000
D18	3943,2	116,2	33,95	0,000
D19	4020,0	116,2	34,61	0,000
D20	4071,5	116,2	35,05	0,000
D21	4123,0	116,2	35,49	0,000
D22	4136,2	118,5	34,92	0,000
D23	4076,4	118,5	34,41	0,000
D24	3929,5	118,5	33,17	0,000
D25	3942,4	118,5	33,28	0,000
D26	4079,0	118,5	34,43	0,000
D27	4249,0	116,2	36,58	0,000
D28	4235,7	116,2	36,46	0,000
D29	4210,3	116,2	36,24	0,000
D30	4171,7	116,2	35,91	0,000
D31	4136,7	116,2	35,61	0,000
D32	4071,2	116,2	35,05	0,000
D33	4067,0	116,2	35,01	0,000
D34	4144,6	116,2	35,68	0,000
D35	4517,1	116,2	38,88	0,000
D36	4671,3	116,2	40,21	0,000
D37	4649,2	116,2	40,02	0,000
D38	4611,9	116,2	39,70	0,000
D39	4601,3	116,2	39,61	0,000
D40	4554,0	116,2	39,20	0,000
D41	4482,3	116,2	38,58	0,000
D42	4360,4	116,2	37,53	0,000

Lampiran 7. *Output Time Series Regression Data 1 Bulan*
(Lanjutan).

D43	4199,7	116,2	36,15	0,000
D44	4066,7	116,2	35,00	0,000
D45	4006,2	116,2	34,48	0,000
D46	3890,9	116,2	33,49	0,000
D47	3801,7	116,2	32,72	0,000
D48	3710,90	99,60	37,26	0,000
H1	142,4	108,6	1,31	0,190
H2	426,8	108,6	3,93	0,000
H3	492,4	108,6	4,53	0,000
H4	484,7	108,4	4,47	0,000
H5	493,5	108,5	4,55	0,000
H6	172,0	140,3	1,23	0,220
J1	-1,3	102,1	-0,01	0,990
J2	-147,8	102,1	-1,45	0,148
J3	-208,4	102,1	-2,04	0,042
J4	-150,3	102,1	-1,47	0,141
J5	-58,5	102,1	-0,57	0,567
S1	340,5	152,5	2,23	0,026
S2	363,4	152,5	2,38	0,017
S3	346,2	152,5	2,27	0,023
S4	353,2	152,5	2,32	0,021
S5	365,4	152,5	2,40	0,017
S6	329,8	152,5	2,16	0,031
S7	340,0	152,5	2,23	0,026
S8	322,6	152,5	2,12	0,035
S9	313,2	152,5	2,05	0,040
S10	302,8	152,5	1,99	0,047
S11	278,5	152,5	1,83	0,068
S12	300,0	152,5	1,97	0,049
S13	208,6	152,5	1,37	0,172
S14	176,0	152,5	1,15	0,249
S15	54,3	152,5	0,36	0,722
S16	20,1	152,5	0,13	0,895
S17	-9,6	152,5	-0,06	0,950
S18	-15,2	152,5	-0,10	0,921
S19	-33,9	152,5	-0,22	0,824
S20	-10,2	152,5	-0,07	0,947
S21	-0,2	152,5	-0,00	0,999
S22	-6,8	154,3	-0,04	0,965
S23	29,5	154,3	0,19	0,848
S24	92,7	154,3	0,60	0,548
S25	28,3	154,3	0,18	0,854
S26	-76,2	154,3	-0,49	0,621
S27	-166,3	152,5	-1,09	0,276
S28	-231,4	152,5	-1,52	0,130

Lampiran 7. *Output Time Series Regression Data 1 Bulan*
(Lanjutan).

S29	-237,9	152,5	-1,56	0,119
S30	-247,2	152,5	-1,62	0,105
S31	-244,4	152,5	-1,60	0,109
S32	-179,6	152,5	-1,18	0,239
S33	-127,0	152,5	-0,83	0,405
S34	-57,5	152,5	-0,38	0,706
S35	-19,8	152,5	-0,13	0,897
S36	-3,8	152,5	-0,02	0,980
S37	-4,5	152,5	-0,03	0,977
S38	1,5	152,5	0,01	0,992
S39	-24,0	152,5	-0,16	0,875
S40	-33,5	152,5	-0,22	0,826
S41	-18,5	152,5	-0,12	0,904
S42	-36,5	152,5	-0,24	0,811
S43	-13,4	152,5	-0,09	0,930
S44	-15,4	152,5	-0,10	0,919
S45	-22,2	152,5	-0,15	0,884
S46	-6,4	152,5	-0,04	0,966
S47	-15,9	152,5	-0,10	0,917
M1	265,9	152,5	1,74	0,082
M2	243,7	152,5	1,60	0,110
M3	253,6	152,5	1,66	0,097
M4	250,8	152,5	1,64	0,100
M5	245,7	152,5	1,61	0,107
M6	249,6	152,5	1,64	0,102
M7	239,1	152,5	1,57	0,117
M8	216,2	152,5	1,42	0,157
M9	176,1	152,5	1,15	0,248
M10	105,5	152,5	0,69	0,489
M11	33,1	152,5	0,22	0,828
M12	63,1	152,5	0,41	0,679
M13	69,0	152,5	0,45	0,651
M14	22,5	152,5	0,15	0,883
M15	-159,8	152,5	-1,05	0,295
M16	-300,4	152,5	-1,97	0,049
M17	-433,7	152,5	-2,84	0,005
M18	-484,1	152,5	-3,17	0,002
M19	-538,2	152,5	-3,53	0,000
M20	-579,9	152,5	-3,80	0,000
M21	-582,3	152,5	-3,82	0,000
M22	-570,8	154,3	-3,70	0,000
M23	-511,1	154,3	-3,31	0,001
M24	-388,5	154,3	-2,52	0,012
M25	-369,9	154,3	-2,40	0,017
M26	-505,0	154,3	-3,27	0,001

**Lampiran 7. Output Time Series Regression Data 1 Bulan
(Lanjutan).**


M27	-673,3	152,5	-4,41	0,000
M28	-660,7	152,5	-4,33	0,000
M29	-653,8	152,5	-4,29	0,000
M30	-620,6	152,5	-4,07	0,000
M31	-555,8	152,5	-3,64	0,000
M32	-470,2	152,5	-3,08	0,002
M33	-402,9	152,5	-2,64	0,008
M34	-331,4	152,5	-2,17	0,030
M35	-250,2	152,5	-1,64	0,101
M36	-136,2	152,5	-0,89	0,372
M37	-124,5	152,5	-0,82	0,414
M38	-119,7	152,5	-0,78	0,433
M39	-103,4	152,5	-0,68	0,498
M40	-111,5	152,5	-0,73	0,465
M41	-79,4	152,5	-0,52	0,603
M42	-51,8	152,5	-0,34	0,734
M43	-29,9	152,5	-0,20	0,845
M44	-41,9	152,5	-0,27	0,784
M45	-28,8	152,5	-0,19	0,850
M46	-19,2	152,5	-0,13	0,900
M47	-16,6	152,5	-0,11	0,914

S = 198,414

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	154	26321397796	170918168	4341,54	0,000
Residual Error	1286	50627406	39368		
Total	1440	26372025202			

Lampiran 8. *Normality Test dan ACF Residual Model Time Series Regression Data 1 Bulan.*



Lampiran 9. Output Pengujian Dickey Fuller Data yang Telah dilakukan *Differencing* lag 1, 48, dan 336 pada Pemodelan *Double Seasonal* ARIMA.

Augmented Dickey-Fuller Test

data: c

Dickey-Fuller = -26.399, Lag order = 25, p-value = 0.01

alternative hypothesis: stationary

Lampiran 10. *Syntax Double Seasonal ARIMA Model 1 atau ARIMA (0,1,1)(0,1,1)⁴⁸(0,1,1)³³⁶.*

```
data listrik;
input y;
datalines;
3498.7
3471.6
3382.7
3336.8
3284.4
:
4091
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate p=(0) (0) (0) q=(1) (48) (336) noconstant
  method=cls;
  forecast out=ramalan lead=336;
  run;
proc export data=work.ramalan
  outfile="d:\ramalan_ARIMA_1.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;
```


Lampiran 11. *Output Double Seasonal ARIMA Model 1 atau ARIMA (0,1,1)(0,1,1)⁴⁸(0,1,1)³³⁶.*

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.0030448	0.0076828	-0.40	0.6919	1
MA2,1	0.67654	0.0057251	118.17	<.0001	48
MA3,1	0.80128	0.0046993	170.51	<.0001	336

Variance Estimate 1756.311

Std Error Estimate 41.90836

AIC 177139.9

SBC 177163.2

Number of Residuals 17183

* AIC and SBC do not include log determinant.

Correlations of Parameter Estimates

Parameter	MA1,1	MA2,1	MA3,1
MA1,1	1.000	-0.105	-0.036
MA2,1	-0.105	1.000	-0.154
MA3,1	-0.036	-0.154	1.000

Autocorrelation Check of Residuals

To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	39.18	3	<.0001	0.000	0.041	0.006	-0.017	0.015	-0.009
12	110.23	9	<.0001	-0.035	-0.017	0.001	0.035	0.033	0.018
18	184.02	15	<.0001	0.002	0.000	-0.002	-0.034	-0.032	-0.045
24	384.92	21	<.0001	-0.041	-0.070	-0.055	-0.042	-0.015	-0.003
30	414.60	27	<.0001	-0.007	-0.017	-0.024	-0.016	-0.023	0.006
36	425.68	33	<.0001	-0.016	-0.012	0.001	0.010	0.005	0.012
42	444.20	39	<.0001	0.016	0.014	0.003	-0.004	-0.022	-0.010
48	604.14	45	<.0001	-0.024	-0.008	-0.013	0.002	0.092	0.002

Lampiran 12. *Syntax Double Seasonal ARIMA Model 2 atau ARIMA ([1,2,4,5,7,10,16,18,20,21,27,30,41,43], 1,1)([47],1,1)⁴⁸(0,1,1)³³⁶.*

```
data listrik;
input y;
datalines;
3498.7
3471.6
3382.7
3336.8
3284.4
:
4091
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate p=(1,2,4,5,7,10,16,18,20,21,27,30,41,43) (47) (0)
  q=(1) (48) (336) noconstant
  method=cls;
  forecast out=ramalan lead=336;
  run;
proc export data=work.ramalan
  outfile="d:\ramalan_ARIMA_2.xls"
  dbms=excel97
  replace;
  sheet="1";
```

Lampiran 13. *Output Double Seasonal ARIMA Model 2 atau ARIMA ([1,2,4,5,7,10,16,18,20,21,27,30,41,43], 1,1)([47],1,1)⁴⁸(0,1,1)³³⁶.*

The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.57420	0.04889	11.74	<.0001	1				
MA2,1	0.69780	0.0056273	124.00	<.0001	48				
MA3,1	0.80572	0.0046651	172.71	<.0001	336				
AR1,1	0.56445	0.04906	11.51	<.0001	1				
AR1,2	0.02081	0.0079503	2.62	0.0089	2				
AR1,3	-0.02703	0.0079950	-3.38	0.0007	4				
AR1,4	0.01975	0.0079836	2.47	0.0134	5				
AR1,5	-0.03405	0.0067353	-5.05	<.0001	7				
AR1,6	0.04680	0.0063256	7.40	<.0001	10				
AR1,7	-0.04016	0.0065596	-6.12	<.0001	16				
AR1,8	-0.03094	0.0075594	-4.09	<.0001	18				
AR1,9	-0.05825	0.0082973	-7.02	<.0001	20				
AR1,10	-0.02231	0.0096593	-2.31	0.0209	21				
AR1,11	-0.02641	0.0066695	-3.96	<.0001	27				
AR1,12	0.01501	0.0063622	2.36	0.0184	30				
AR1,13	-0.03481	0.0066336	-5.25	<.0001	41				
AR1,14	-0.01515	0.0069672	-2.18	0.0296	43				
AR2,1	0.08326	0.0077267	10.78	<.0001	47				
Variance Estimate			1703.519						
Std Error Estimate			41.27371						
AIC			176630.5						
SBC			176770						
Number of Residuals			17183						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.001	0.007	-0.012	0.001	0.008	-0.010
12	.	0	.	-0.002	0.001	0.013	-0.004	0.009	-0.000
18	.	0	.	-0.011	-0.006	-0.008	0.005	-0.010	0.005
24	22.53	6	0.0010	-0.016	-0.000	0.005	-0.007	-0.001	0.001
30	28.67	12	0.0044	-0.007	-0.012	0.005	0.004	-0.002	0.010
36	33.21	18	0.0157	-0.006	-0.007	0.007	0.005	-0.008	-0.006
42	41.74	24	0.0138	0.002	-0.001	-0.014	-0.017	0.001	-0.002
48	48.80	30	0.0165	-0.007	-0.003	-0.017	-0.002	-0.000	0.008

Lampiran 14. *Syntax Double Seasonal ARIMA Data 1 Bulan*
 ARIMA ([5,6,11,20,24,30,42],1,1)(0,1,1)⁴⁸
 (0,1,1)³³⁶.

```
data listrik;
input y;
datalines;
3988.1
3945.2
3959.5
3909.4
3800.0
:
4091
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate p=(5,6,11,20,24,30,42) (0) (0)
  q=(1) (48) (336) noconstant
  method=cls;
  forecast out=ramalan lead=336;
  run;
proc export data=work.ram1alan
  outfile="d:\ramalan_1bulan.xls"
  dbms=excel97
  replace;
  sheet="1";
```

Lampiran 15. *Output Double Seasonal ARIMA Data 1 Bulan*
atau ARIMA ([5,6,11,20,24,30,42],1,1)(0,1,1)⁴⁸
(0,1,1)³³⁶.

The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	0.09273		0.03096	3.00	0.0028	1			
MA2,1	0.68026		0.02352	28.92	<.0001	48			
MA3,1	0.56151		0.03234	17.36	<.0001	336			
AR1,1	0.06889		0.03029	2.27	0.0232	5			
AR1,2	0.07010		0.03052	2.30	0.0218	6			
AR1,3	0.07391		0.03043	2.43	0.0153	11			
AR1,4	-0.12768		0.03046	-4.19	<.0001	20			
AR1,5	0.06310		0.03052	2.07	0.0390	24			
AR1,6	0.07668		0.03050	2.51	0.0121	30			
AR1,7	-0.09072		0.03056	-2.97	0.0031	42			
Variance Estimate				2639.192					
Std Error Estimate				51.37306					
AIC				11315.44					
SBC				11365.06					
Number of Residuals				1055					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.003	0.028	0.012	0.007	-0.000	0.007
12	7.10	2	0.0288	-0.042	0.054	0.024	0.009	0.010	-0.013
18	12.34	8	0.1366	-0.001	0.050	-0.030	-0.001	-0.025	-0.030
24	26.08	14	0.0253	-0.046	-0.002	-0.063	-0.058	-0.058	-0.004
30	30.35	20	0.0644	0.019	0.043	0.039	0.009	0.008	-0.006
36	36.56	26	0.0819	0.005	-0.009	0.010	-0.039	0.050	0.038
42	44.00	32	0.0768	-0.032	-0.041	-0.056	0.024	-0.018	-0.005
48	50.72	38	0.0812	0.016	-0.002	-0.038	-0.065	0.011	0.005

Lampiran 16. *Output Random Forest Window 1 Model Time Series Regression.*

```
>d=read.csv("D:/nay/RF_TSR_window time/model 1.csv",header=T,sep=",")
>vd <- VSURF(Yt ~ ., data = d, ntree=1000, nfor.thres=40, nfor.interp=20,
nfor.pred=20, nmin=10)
> summary(vd)

VSURF computation time: 2.2 hours

VSURF selected:
      65 variables at thresholding step (in 39.8 mins)
      60 variables at interpretation step (in 1.4 hours)
      2 variables at prediction step (in 4.2 mins)
> plot(vd, step = "thres", imp.sd = FALSE, var.names = TRUE)
> number <- c(1:157)
> number[vd$vselect.thres]
[1] 56  1 50 37 55 38 39 40 41 15 36 14 42  8  7  6  9  5  4 13 16
3 43 10
[25]  2 54 53 12 49 11 52 17 48 28 44 51 29 145 146 147 148 47 149
150 30 144 151 25
[49] 46 45 26 152 96 102 101 35 100 99 31 98 97 103 18 153 75
> number[vd$vselect.interp]
[1] 56  1 50 37 55 38 39 40 41 15 36 14 42  8  7  6  9  5  4 13 16
3 43 10
[25]  2 54 53 12 49 11 52 17 48 28 44 51 29 145 146 147 148 47 149
150 30 144 151 25
[49] 46 45 26 152 96 102 101 35 100 99 31 98
> number[vd$vselect.pred]
[1] 56 1
```

Lampiran 17. *Output Random Forest Window 2 Model Time Series Regression.*

```
> d=read.csv("D:/nay/RF_TSR_window time/model 2.csv",header=T,sep=",")
> vd <- VSURF(Yt ~ ., data = d, ntree=1000, nfor.thres=40, nfor.interp=20,
  nfor.pred=20, nmin=10)
> summary(vd)

VSURF computation time: 3.6 hours

VSURF selected:
      92 variables at thresholding step (in 39.9 mins)
      66 variables at interpretation step (in 2.9 hours)
       2 variables at prediction step (in 4.6 mins)
> plot(vd, step = "thres", imp.sd = FALSE, var.names = TRUE)
> number <- c(1:157)
> number[vd$vselect.thres]
[1] 56  1 50 55 37 38 39 40 41 36 15 14 42  8  7  6  9  5  4 13 54
16 43  3
[25] 10  2 53 52 12 49 11 17 48 51 44 28 29 145 146 148 147 47 149
150 30 144 151 25
[49] 96 101 100 99 102 98 45 97 46 152 26 35 103 75 31 76 74 153
18 59 154 104 109 77
[73] 60 82 123 83 68 110 67 84 124 58 95 155 143 69 119 108 88 125
122 66
> number[vd$vselect.interp]
[1] 56  1 50 55 37 38 39 40 41 36 15 14 42  8  7  6  9  5  4 13 54
16 43  3
[25] 10  2 53 52 12 49 11 17 48 51 44 28 29 145 146 148 147 47 149
150 30 144 151 25
[49] 96 101 100 99 102 98 45 97 46 152 26 35 103 75 31 76 74 153
> number[vd$vselect.pred]
[1] 56 1
```

Lampiran 18. *Output Random Forest Window 3 Model Time Series Regression.*

```
> d=read.csv("D:/nay/RF_TSR_window time/model 3.csv",header=T,sep=",")
> vd <- VSURF(Yt ~ ., data = d, ntree=1000, nfor.thres=40, nfor.interp=20,
  nfor.pred=20, nmin=10)
> summary(vd)
```

VSURF computation time: 2.3 hours

VSURF selected:

68 variables at thresholding step (in 40.1 mins)

62 variables at interpretation step (in 1.5 hours)

2 variables at prediction step (in 4.3 mins)

```
> plot(vd, step = "thres", imp.sd = FALSE, var.names = TRUE)
```

```
> number <- c(1:157)
```

```
> number[vd$vselect.thres]
```

```
[1] 56 1 50 55 37 38 39 40 41 36 15 14 42 8 7 6 9 5 53 13 4
43 54 16
```

```
[25] 3 10 52 2 12 49 11 51 17 44 48 146 145 148 147 149 150 28 144
151 47 29 45 152
```

```
[49] 30 46 96 100 25 99 101 102 98 97 35 153 103 26 75 154 76 74
18 31
```

```
> number[vd$vselect.interp]
```

```
[1] 56 1 50 55 37 38 39 40 41 36 15 14 42 8 7 6 9 5 53 13 4
43 54 16
```

```
[25] 3 10 52 2 12 49 11 51 17 44 48 146 145 148 147 149 150 28 144
151 47 29 45 152
```

```
[49] 30 46 96 100 25 99 101 102 98 97 35 153 103 26
```

```
> number[vd$vselect.pred]
```

```
[1] 56 1
```


Lampiran 19. *Output Random Forest Window 4 Model Time Series Regression.*

```
> d=read.csv("D:/nay/RF_TSR_window time/model 4.csv",header=T,sep=",")
> vd <- VSURF(Yt ~ ., data = d, ntree=1000, nfor.thres=40, nfor.interp=20,
  nfor.pred=20, nmin=10)
> summary(vd)
```

VSURF computation time: 3.1 hours

VSURF selected:

83 variables at thresholding step (in 40.7 mins)

64 variables at interpretation step (in 2.4 hours)

2 variables at prediction step (in 4.6 mins)

```
> plot(vd, step = "thres", imp.sd = FALSE, var.names = TRUE)
> number <- c(1:157)
> number[vd$vselect.thres]
[1] 56 1 50 55 37 38 39 40 41 36 15 14 42 8 7 6 9 5 53 54 4
13 43 16
[25] 3 52 10 2 12 49 11 51 17 48 44 146 145 148 147 149 150 28 151
144 29 47 30 152
[49] 45 46 25 35 26 96 153 99 100 98 101 102 97 18 154 31 103 75
76 74 155 59 123 110
[73] 143 124 77 109 104 119 60 83 125 122 82
> number[vd$vselect.interp]
[1] 56 1 50 55 37 38 39 40 41 36 15 14 42 8 7 6 9 5 53 54 4
13 43 16
[25] 3 52 10 2 12 49 11 51 17 48 44 146 145 148 147 149 150 28 151
144 29 47 30 152
[49] 45 46 25 35 26 96 153 99 100 98 101 102 97 18 154 31
> number[vd$vselect.pred]
[1] 56 1
```

Lampiran 20. *Output Random Forest Window 5 Model Time Series Regression.*

```
> d=read.csv("D:/nay/RF_TSR_window time/model 5.csv",header=T,sep=",")
> View(d)
> vd <- VSURF(Yt ~ ., data = d, ntree=1000, nfor.thres=40, nfor.interp=20,
  nfor.pred=20, nmin=10)
> summary(vd)
```

VSURF computation time: 3.1 hours

VSURF selected:

83 variables at thresholding step (in 40.6 mins)

60 variables at interpretation step (in 2.4 hours)

2 variables at prediction step (in 4.5 mins)

```
> plot(vd, step = "thres", imp.sd = FALSE, var.names = TRUE)
> number <- c(1:157)
> number[vd$varselect.thres]
[1] 56 1 50 55 37 38 39 40 41 36 15 14 42 8 7 6 9 5 4 13 3
16 43 10
[25] 2 53 54 12 52 49 11 51 17 48 44 28 29 146 145 148 147 149 47
150 151 144 30 25
[49] 46 45 152 26 35 18 96 101 102 99 100 98 97 153 31 103 154 76
75 74 59 123 77 109
[73] 110 155 104 124 83 60 82 119 122 143 58
> number[vd$varselect.interp]
[1] 56 1 50 55 37 38 39 40 41 36 15 14 42 8 7 6 9 5 4 13 3
16 43 10
[25] 2 53 54 12 52 49 11 51 17 48 44 28 29 146 145 148 147 149 47
150 151 144 30 25
[49] 46 45 152 26 35 18 96 101 102 99 100 98
> number[vd$varselect.pred]
[1] 56 1
```

Lampiran 21. *Output Random Forest Window 6 Model Time Series Regression.*

```
>d=read.csv("D:/nay/RF_TSR_window time/model 6.csv",header=T,sep=",")
> vd <- VSURF(Yt ~ ., data = d, ntree=1000, nfor.thres=40, nfor.interp=20,
  nfor.pred=20, nmin=10)
> summary(vd)
```

VSURF computation time: 2.4 hours

VSURF selected:

66 variables at thresholding step (in 41.6 mins)

57 variables at interpretation step (in 1.6 hours)

2 variables at prediction step (in 8.8 mins)

```
> plot(vd, step = "thres", imp.sd = FALSE, var.names = TRUE)
```

There were 50 or more warnings (use warnings() to see the first 50)

```
> number <- c(1:157)
```

There were 50 or more warnings (use warnings() to see the first 50)

```
> number[vd$vselect.thres]
```

```
[1] 56 1 50 55 37 38 39 40 41 36 15 14 42 8 7 6 9 5 4 13 3
16 52 43
```

```
[25] 10 53 2 54 12 49 51 11 17 48 44 28 145 146 148 147 29 149 47
150 151 144 30 25
```

```
[49] 46 45 152 26 18 96 35 99 100 102 101 98 97 153 31 103 154 75
```

```
> number[vd$vselect.interp]
```

```
[1] 56 1 50 55 37 38 39 40 41 36 15 14 42 8 7 6 9 5 4 13 3
16 52 43
```

```
[25] 10 53 2 54 12 49 51 11 17 48 44 28 145 146 148 147 29 149 47
150 151 144 30 25
```

```
[49] 46 45 152 26 18 96 35 99 100
```

```
> number[vd$vselect.pred]
```

```
[1] 56 1
```

Lampiran 22. *Output Random Forest Window 7 Model Time Series Regression.*

```
> d=read.csv("D:/nay/RF_TSR_window time/model 7.csv",header=T,sep=",")
> vd <- VSURF(Yt ~ ., data = d, ntree=1000, nfor.thres=40, nfor.interp=20,
nfor.pred=20, nmin=10)
> summary(vd)
```

VSURF computation time: 2.2 hours

VSURF selected:

62 variables at thresholding step (in 41.8 mins)

55 variables at interpretation step (in 1.4 hours)

2 variables at prediction step (in 8.5 mins)

```
> plot(vd, step = "thres", imp.sd = FALSE, var.names = TRUE)
```

There were 50 or more warnings (use warnings() to see the first 50)

```
> number <- c(1:157)
```

There were 50 or more warnings (use warnings() to see the first 50)

```
> number[vd$varselect.thres]
```

```
[1] 56 1 50 55 37 38 39 40 41 36 15 14 42 8 7 53 6 9 5 52 54
13 4 3
```

```
[25] 16 43 10 2 12 49 51 11 17 48 44 28 145 146 147 148 149 47 29
150 151 144 30 25
```

```
[49] 46 45 152 18 26 96 35 99 100 102 101 98 97 153
```

```
> number[vd$varselect.interp]
```

```
[1] 56 1 50 55 37 38 39 40 41 36 15 14 42 8 7 53 6 9 5 52 54
13 4 3
```

```
[25] 16 43 10 2 12 49 51 11 17 48 44 28 145 146 147 148 149 47 29
150 151 144 30 25
```


```
[49] 46 45 152 18 26 96 35
```

```
> number[vd$varselect.pred]
```


```
[1] 56 1
```

Lampiran 23. *Output Plot Ranking Variabel dengan Random Forest pada Model Time Time Series Regression Window 1-7.*


a. *Window 1*




b. *Window 2*




c. Window 3




d. Window 4




e. Window 5



f. Window 6



g. Window 7



Lampiran 24. *Output Time Series Regression Window 1 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.*

The regression equation is

$$Y(t) = 855 H7 + 4,33 t$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	854,9	161,6	5,29	0,000
t	4,33160	0,07093	61,07	0,000

$$S = 2139,25$$

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	19791162493	9895581246	2162,31	0,000
Residual Error	1438	6580862710	4576400		
Total	1440	26372025202			

Source	DF	Seq SS
H7	1	2725811897
t	1	17065350596

Lampiran 25. *Output Time Series Regression Window 2 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.*

The regression equation is

$$Y(t) = 1082 H7 + 4,30 t$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	1082,0	159,6	6,78	0,000
t	4,30092	0,07004	61,40	0,000

$$S = 2126,22$$

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	19771329815	9885664908	2186,71	0,000
Residual Error	1438	6500912275	4520801		
Total	1440	26272242090			

Source	DF	Seq SS
H7	1	2725811897
t	1	17045517918

Lampiran 26. *Output Time Series Regression Window 3 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.*

The regression equation is

$$Y(t) = 555 H7 + 4,29 t$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	554,6	149,9	3,70	0,000
t	4,29344	0,07355	58,37	0,000

S = 2161,20

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	19291419950	9645709975	2065,11	0,000
Residual Error	1438	6716594408	4670789		
Total	1440	26008014358			

Source	DF	Seq SS
H7	1	3377000546
t	1	15914419404

Lampiran 27. *Output Time Series Regression Window 4 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.*

The regression equation is

$$Y(t) = 787 H7 + 4,26 t$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	787,1	148,2	5,31	0,000
t	4,25551	0,07274	58,51	0,000

S = 2157,60

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	19312117151	9656058576	2074,23	0,000
Residual Error	1438	6694239897	4655243		
Total	1440	26006357049			

Source	DF	Seq SS
H7	1	3377000546
t	1	15935116605

Lampiran 28. *Output Time Series Regression Window 5 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.*

The regression equation is

$$Y(t) = 172 \text{ H7} + 4,36 \text{ t}$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	172,5	170,2	1,01	0,311
t	4,36407	0,07473	58,40	0,000

S = 2202,12

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	19217573604	9608786802	1981,47	0,000
Residual Error	1438	6973339297	4849332		
Total	1440	26190912901			

Source	DF	Seq SS
H7	1	2679524965
t	1	16538048639

Lampiran 29. *Output Time Series Regression Window 6 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.*

The regression equation is

$$Y(t) = 397 \text{ H7} + 4,34 \text{ t}$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	397,5	167,6	2,37	0,018
t	4,34387	0,07356	59,05	0,000

S = 2185,79

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	19340519425	9670259713	2024,06	0,000
Residual Error	1438	6870282167	4777665		
Total	1440	26210801592			

Source	DF	Seq SS
H7	1	2679524965
t	1	16660994460

Lampiran 30. *Output Time Series Regression Window 7 dengan Variabel Preditor Hasil Seleksi Tahap 3 Random Forest.*

The regression equation is

$$Y(t) = 616 H7 + 4,33 t$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	615,5	164,4	3,74	0,000
t	4,33064	0,07216	60,01	0,000

S = 2160,93


Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	19496489183	9748244591	2087,58	0,000
Residual Error	1438	6714939819	4669638		
Total	1440	26211429002			


Source	DF	Seq SS
H7	1	2679524965
t	1	16816964218

Lampiran 31. Normality Test dan ACF Residual *Window 1-7 Model Time Series Regression* dengan Variabel Preditor Hasil Seleksi Tahap 3 *Random Forest*.


a. *Window 1*




Mean 1019
StDev 1880
N 1440
KS 0,080
P-Value <0,010




b. Window 2




c. Window 3




d. Window 4




e. Window 5



f. Window 6



g. Window 7



Lampiran 32. Output Time Series Regression Window 1 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest.

The regression equation is

$$Y(t) = 3802 H7 - 0,0089 t + 4136 H1 + 669 D36 + 4233 H6 + 658 D37 + 621 D38 + 610 D39 + 563 D40 - 601 D14 + 526 D35 - 586 D13 + 491 D41 - 511 D7 - 510 D6 - 480 D5 - 463 D8 - 447 D4 - 405 D3 - 433 D12 - 454 D15 - 373 D2 + 353 D42 - 344 D9 - 327 D1 + 4476 H5 + 4478 H4 - 276 D11 - 265 D48 - 227 D10 + 4486 H3 - 306 D16 - 178 D47 + 162 D27 + 196 D43 + 4421 H2 + 141 D28 + 64 M36 + 65 M37 + 69 M38 + 86 M39 - 88,0 D46 + 78 M40 + 110 M41 + 116 D29 - 61 M35 + 154 M42 - 120 D24 + 24,0 D45 + 83,6 D44 - 104 D25 + 172 M43 - 90 S35 - 88 S41 - 103 S40 + 117 D34 - 94 S39 - 68 S38 + 80,6 D30 - 74 S37$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	3802,01	23,00	165,30	0,000
t	-0,00890	0,01442	-0,62	0,537
H1	4136,26	22,19	186,39	0,000
D36	668,67	45,94	14,56	0,000
H6	4233,14	22,28	189,98	0,000
D37	657,83	49,73	13,23	0,000
D38	620,55	49,73	12,48	0,000
D39	610,01	49,73	12,27	0,000
D40	562,64	49,73	11,31	0,000
D14	-600,80	42,93	-13,99	0,000
D35	525,74	49,73	10,57	0,000
D13	-586,45	42,93	-13,66	0,000
D41	491,01	49,73	9,87	0,000
D7	-511,34	42,94	-11,91	0,000
D6	-509,87	42,94	-11,88	0,000
D5	-479,60	42,94	-11,17	0,000
D8	-462,60	42,94	-10,77	0,000
D4	-446,63	42,94	-10,40	0,000
D3	-405,22	42,94	-9,44	0,000
D12	-433,24	42,93	-10,09	0,000
D15	-453,53	42,93	-10,56	0,000
D2	-373,23	42,94	-8,69	0,000
D42	352,65	45,94	7,68	0,000
D9	-344,24	42,93	-8,02	0,000
D1	-326,68	42,94	-7,61	0,000
H5	4475,54	21,14	211,70	0,000
H4	4478,49	20,80	215,33	0,000

**Lampiran 32. Output Time Series Regression Window 1 dengan
Variabel Preditor Hasil Seleksi Tahap 2 Random
Forest (Lanjutan).**

D11	-275,65	42,93	-6,42	0,000
D48	-264,55	42,94	-6,16	0,000
D10	-226,98	42,93	-5,29	0,000
H3	4486,23	22,87	196,15	0,000
D16	-305,73	42,93	-7,12	0,000
D47	-178,09	42,94	-4,15	0,000
D27	161,63	42,93	3,76	0,000
D43	195,55	45,94	4,26	0,000
H2	4420,59	22,52	196,27	0,000
D28	141,27	42,93	3,29	0,001
M36	64,3	122,5	0,53	0,599
M37	64,6	123,9	0,52	0,602
M38	69,4	123,9	0,56	0,575
M39	85,8	123,9	0,69	0,489
D46	-87,97	42,94	-2,05	0,041
M40	77,6	123,9	0,63	0,531
M41	109,7	123,9	0,89	0,376
D29	116,00	42,93	2,70	0,007
M35	-61,1	123,9	-0,49	0,622
M42	153,7	122,5	1,26	0,210
D24	-120,16	42,93	-2,80	0,005
D45	23,95	42,94	0,56	0,577
D44	83,63	42,94	1,95	0,052
D25	-103,65	42,93	-2,41	0,016
M43	172,1	122,5	1,41	0,160
S35	-89,7	123,8	-0,72	0,469
S41	-88,4	123,8	-0,71	0,475
S40	-103,4	123,8	-0,83	0,404
D34	117,33	42,93	2,73	0,006
S39	-93,9	123,8	-0,76	0,448
S38	-68,4	123,8	-0,55	0,581
D30	80,57	42,93	1,88	0,061
S37	-74,4	123,8	-0,60	0,548

S = 225,150

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	60	26302069392	438367823	8647,57	0,000
Residual Error	1380	69955811	50693		
Total	1440	26372025202			

Lampiran 33. Output Time Series Regression Window 2 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest.

The regression equation is

$$Y(t) = 3814 H7 - 0,0366 t + 4153 H1 + 4238 H6 + 685 D36 + 662 D37 + 622 D38 + 615 D39 + 569 D40 + 529 D35 - 610 D14 - 599 D13 + 496 D41 - 502 D7 - 500 D6 - 469 D5 - 453 D8 - 439 D4 - 398 D3 - 429 D12 + 4493 H5 - 451 D15 + 375 D42 - 365 D2 - 335 D9 - 317 D1 + 4526 H4 + 4506 H3 - 271 D11 - 266 D48 - 220 D10 - 305 D16 - 181 D47 + 4439 H2 + 191 D43 + 151 D27 + 133 D28 + 53 M36 + 65 M37 + 85 M39 + 73 M38 - 89,9 D46 + 77 M40 + 110 M41 + 109 D29 - 59 M35 + 137 M42 - 117 D24 - 85 S35 - 130 S40 - 111 S39 - 78 S38 - 105 S41 - 87 S37 + 57,6 D44 - 90 S36 + 22,3 D45 + 182 M43 - 105 D25 + 118 D34 - 128 S42 + 77 S14 + 72,1 D30 + 5 S15 + 113 S13 + 170 M44$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	3814,10	22,94	166,27	0,000
t	-0,03660	0,01444	-2,53	0,011
H1	4152,97	21,95	189,16	0,000
H6	4238,48	22,34	189,71	0,000
D36	684,92	50,95	13,44	0,000
D37	662,41	50,95	13,00	0,000
D38	621,86	50,95	12,21	0,000
D39	615,49	50,95	12,08	0,000
D40	568,68	50,95	11,16	0,000
D35	528,67	50,95	10,38	0,000
D14	-609,99	46,89	-13,01	0,000
D13	-598,97	46,89	-12,77	0,000
D41	496,47	50,95	9,74	0,000
D7	-502,25	43,01	-11,68	0,000
D6	-499,50	43,01	-11,61	0,000
D5	-469,11	43,01	-10,91	0,000
D8	-453,16	43,01	-10,54	0,000
D4	-439,08	43,01	-10,21	0,000
D3	-398,17	43,01	-9,26	0,000
D12	-429,00	43,01	-9,97	0,000
H5	4492,91	20,88	215,21	0,000
D15	-451,01	46,89	-9,62	0,000
D42	374,80	50,95	7,36	0,000
D2	-364,84	43,01	-8,48	0,000
D9	-335,32	43,01	-7,80	0,000
D1	-317,50	43,01	-7,38	0,000

Lampiran 33. *Output Time Series Regression Window 2 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest (Lanjutan).*

H4	4525,56	22,95	197,19	0,000
H3	4505,59	22,60	199,35	0,000
D11	-270,87	43,01	-6,30	0,000
D48	-265,74	43,01	-6,18	0,000
D10	-219,99	43,01	-5,11	0,000
D16	-305,15	43,01	-7,09	0,000
D47	-180,91	43,01	-4,21	0,000
H2	4438,62	22,27	199,31	0,000
D43	190,72	46,02	4,14	0,000
D27	150,90	43,01	3,51	0,000
D28	132,58	43,01	3,08	0,002
M36	53,2	124,7	0,43	0,670
M37	65,2	124,7	0,52	0,601
M39	85,5	124,7	0,69	0,493
M38	73,3	124,7	0,59	0,557
D46	-89,94	43,01	-2,09	0,037
M40	76,8	124,7	0,62	0,538
M41	109,5	124,7	0,88	0,380
D29	109,13	43,01	2,54	0,011
M35	-58,9	124,7	-0,47	0,636
M42	136,8	124,7	1,10	0,273
D24	-116,62	43,01	-2,71	0,007
S35	-85,2	113,7	-0,75	0,454
S40	-130,1	113,7	-1,14	0,253
S39	-110,8	113,7	-0,97	0,330
S38	-78,0	113,7	-0,69	0,493
S41	-105,4	113,7	-0,93	0,354
S37	-87,2	113,7	-0,77	0,444
D44	57,64	46,02	1,25	0,211
S36	-90,2	113,7	-0,79	0,428
D45	22,32	43,01	0,52	0,604
M43	182,2	122,7	1,48	0,138
D25	-104,80	43,01	-2,44	0,015
D34	118,16	43,01	2,75	0,006
S42	-128,4	113,7	-1,13	0,259
S14	76,6	112,0	0,68	0,494
D30	72,08	43,01	1,68	0,094
S15	5,0	112,0	0,04	0,964
S13	112,8	112,0	1,01	0,314
M44	170,3	122,7	1,39	0,165

Lampiran 33. *Output Time Series Regression Window 2 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest (Lanjutan).*

S = 225,553

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	66	26202340792	397005164	7803,65	0,000
Residual Error	1374	69901298	50874		
Total	1440	26272242090			

Lampiran 34. *Output Time Series Regression Window 3 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest.*

The regression equation is

$$Y(t) = 3812 H7 - 0,0574 t + 4159 H1 + 4251 H6 + 691 D36 + 670 D37 + 628 D38 + 622 D39 + 579 D40 + 538 D35 - 588 D14 - 570 D13 + 504 D41 - 485 D7 - 482 D6 - 452 D5 - 436 D8 - 423 D4 + 4534 H4 - 417 D12 - 381 D3 + 382 D42 + 4524 H5 - 447 D15 - 347 D2 - 321 D9 + 4513 H3 - 301 D1 - 260 D11 - 253 D48 - 209 D10 + 4445 H2 - 304 D16 + 197 D43 - 169 D47 + 65 M37 + 52 M36 + 89 M39 + 83 M38 + 73 M40 + 99 M41 + 137 D27 - 36 M35 + 124 M42 - 78,3 D46 + 121 D28 + 64,3 D44 + 166 M43 + 97,9 D29 + 33,7 D45 - 94 S35 - 116 S39 - 114 D24 - 84 S38 - 140 S40 - 112 S41 - 94 S37 - 96 S36 + 122 D34 + 158 M44 - 135 S42 - 104 D25$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	3812,24	22,18	171,86	0,000
t	-0,05743	0,01462	-3,93	0,000
H1	4158,80	21,63	192,30	0,000
H6	4251,04	21,59	196,86	0,000
D36	691,29	52,67	13,12	0,000
D37	669,99	52,67	12,72	0,000
D38	627,99	52,67	11,92	0,000
D39	621,61	52,67	11,80	0,000
D40	579,01	52,67	10,99	0,000
D35	538,13	52,67	10,22	0,000
D14	-587,66	43,40	-13,54	0,000
D13	-569,96	43,40	-13,13	0,000
D41	503,83	52,67	9,56	0,000

Lampiran 34. *Output Time Series Regression Window 3 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest (Lanjutan).*

D7	-485,25	43,40	-11,18	0,000
D6	-482,12	43,40	-11,11	0,000
D5	-452,29	43,40	-10,42	0,000
D8	-435,93	43,40	-10,05	0,000
D4	-423,29	43,40	-9,75	0,000
H4	4534,39	22,60	200,67	0,000
D12	-417,17	43,40	-9,61	0,000
D3	-381,14	43,40	-8,78	0,000
D42	382,03	52,67	7,25	0,000
H5	4523,69	22,95	197,08	0,000
D15	-447,25	43,40	-10,31	0,000
D2	-347,47	43,40	-8,01	0,000
D9	-321,39	43,40	-7,41	0,000
H3	4513,43	22,26	202,80	0,000
D1	-300,64	43,40	-6,93	0,000
D11	-260,30	43,40	-6,00	0,000
D48	-253,01	43,40	-5,83	0,000
D10	-208,54	43,40	-4,81	0,000
H2	4445,45	21,93	202,69	0,000
D16	-304,24	43,40	-7,01	0,000
D43	197,34	47,33	4,17	0,000
D47	-169,07	43,40	-3,90	0,000
M37	64,8	115,7	0,56	0,575
M36	52,2	115,7	0,45	0,652
M39	89,4	115,7	0,77	0,440
M38	82,9	115,7	0,72	0,474
M40	72,8	115,7	0,63	0,529
M41	99,3	115,7	0,86	0,391
D27	137,02	43,40	3,16	0,002
M35	-35,7	115,7	-0,31	0,757
M42	123,5	115,7	1,07	0,286
D46	-78,31	43,40	-1,80	0,071
D28	121,00	43,40	2,79	0,005
D44	64,32	47,33	1,36	0,174
M43	165,8	113,3	1,46	0,144
D29	97,90	43,40	2,26	0,024
D45	33,72	43,40	0,78	0,437
S35	-94,3	115,6	-0,82	0,415
S39	-116,5	115,6	-1,01	0,314
D24	-114,00	43,40	-2,63	0,009
S38	-83,6	115,6	-0,72	0,469
S40	-140,0	115,6	-1,21	0,226

Lampiran 34. *Output Time Series Regression Window 3 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest (Lanjutan).*

S41	-112,3	115,6	-0,97	0,332	
S37	-94,3	115,6	-0,82	0,415	
S36	-96,2	115,6	-0,83	0,406	
D34	122,41	43,40	2,82	0,005	
M44	158,2	113,3	1,40	0,163	
S42	-135,1	115,6	-1,17	0,243	
D25	-103,64	43,40	-2,39	0,017	
S = 228,364					
Analysis of Variance					
Source	DF	SS	MS	F	P
Regression	62	25936151209	418325020	8021,52	0,000
Residual Error	1378	71863149	52150		
Total	1440	26008014358			

Lampiran 35. *Output Time Series Regression Window 4 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest.*

The regression equation is					
Y(t) = 3818 H7 - 0,0486 t + 4191 H1 + 4265 H6 + 670 D36 + 650 D37 + 609 D38 + 601 D39 + 558 D40 + 523 D35 - 611 D14 - 598 D13 + 483 D41 - 519 D7 - 514 D6 - 487 D5 - 467 D8 - 457 D4 + 4545 H4 + 4534 H5 - 414 D3 - 448 D12 + 339 D42 - 468 D15 - 382 D2 + 4525 H3 - 352 D9 - 334 D1 - 292 D11 - 269 D48 - 240 D10 + 4457 H2 - 323 D16 - 185 D47 + 178 D43 + 70 M37 + 58 M36 + 95 M39 + 87 M38 + 79 M40 + 105 M41 + 129 D27 + 152 M42 - 36 M35 + 117 D28 - 95,0 D46 + 97,4 D29 + 170 M43 + 44,4 D44 - 12,1 D45 - 129 D24 + 115 D34 - 118 D25 - 82 S35 + 163 M44 - 80 S38 - 109 S39 - 95 S37 - 130 S40 - 105 S41 - 96 S36 - 175 D17 + 177 M45 + 59,4 D30					
Predictor	Coef	SE Coef	T	P	
Noconstant					
H7	3818,21	22,70	168,18	0,000	
t	-0,04862	0,01467	-3,32	0,001	
H1	4190,55	21,90	191,32	0,000	
H6	4264,97	24,42	174,65	0,000	
D36	670,26	51,88	12,92	0,000	
D37	649,81	51,88	12,53	0,000	

**Lampiran 35. Output Time Series Regression Window 4 dengan
Variabel Preditor Hasil Seleksi Tahap 2 Random
Forest (Lanjutan).**

D38	609,28	51,88	11,74	0,000
D39	601,24	51,88	11,59	0,000
D40	557,97	51,88	10,75	0,000
D35	523,19	51,88	10,08	0,000
D14	-610,60	43,85	-13,92	0,000
D13	-597,66	43,85	-13,63	0,000
D41	482,93	51,88	9,31	0,000
D7	-519,31	43,85	-11,84	0,000
D6	-514,43	43,85	-11,73	0,000
D5	-487,13	43,85	-11,11	0,000
D8	-467,33	43,85	-10,66	0,000
D4	-457,10	43,85	-10,42	0,000
H4	4545,28	22,95	198,03	0,000
H5	4534,16	23,29	194,72	0,000
D3	-413,86	43,85	-9,44	0,000
D12	-447,65	43,85	-10,21	0,000
D42	338,84	47,77	7,09	0,000
D15	-468,37	43,85	-10,68	0,000
D2	-382,37	43,85	-8,72	0,000
H3	4524,74	22,64	199,88	0,000
D9	-351,99	43,85	-8,03	0,000
D1	-333,64	43,86	-7,61	0,000
D11	-292,43	43,85	-6,67	0,000
D48	-268,54	43,86	-6,12	0,000
D10	-240,28	43,85	-5,48	0,000
H2	4457,19	22,34	199,52	0,000
D16	-323,36	43,85	-7,37	0,000
D47	-184,74	43,85	-4,21	0,000
D43	178,41	47,77	3,73	0,000
M37	70,0	115,5	0,61	0,544
M36	58,3	115,5	0,50	0,614
M39	94,8	115,5	0,82	0,412
M38	86,6	115,5	0,75	0,454
M40	78,8	115,5	0,68	0,495
M41	105,2	115,5	0,91	0,362
D27	129,35	43,85	2,95	0,003
M42	151,7	113,7	1,33	0,182
M35	-35,7	115,5	-0,31	0,757
D28	116,67	43,85	2,66	0,008
D46	-94,95	43,85	-2,17	0,031
D29	97,44	43,85	2,22	0,026
M43	169,7	113,7	1,49	0,136
D44	44,39	47,77	0,93	0,353

Lampiran 35. Output Time Series Regression Window 4 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest (Lanjutan).

D45	-12,15	47,77	-0,25	0,799
D24	-128,63	43,85	-2,93	0,003
D34	115,14	43,85	2,63	0,009
D25	-118,04	43,85	-2,69	0,007
S35	-81,6	126,5	-0,64	0,519
M44	163,1	113,7	1,43	0,152
S38	-80,4	126,5	-0,64	0,525
S39	-108,9	126,5	-0,86	0,389
S37	-95,2	126,5	-0,75	0,452
S40	-130,5	126,5	-1,03	0,302
S41	-105,1	126,5	-0,83	0,406
S36	-96,0	126,5	-0,76	0,448
D17	-174,81	43,85	-3,99	0,000
M45	177,3	113,7	1,56	0,119
D30	59,40	43,85	1,35	0,176

S = 229,019

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	64	25934186411	405221663	7725,93	0,000
Residual Error	1376	72170638	52450		
Total	1440	26006357049			

Lampiran 36. Output Time Series Regression Window 5 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest.

The regression equation is

$$\begin{aligned}
 Y(t) = & 3835 H7 - 0,0502 t + 4205 H1 + 4278 H6 + 640 D36 + 636 \\
 & D37 + 596 D38 + 591 D39 + 545 D40 + 514 D35 - 634 D14 - \\
 & 625 D13 + 468 D41 - 552 D7 - 547 D6 - 520 D5 - 498 D8 - \\
 & 490 D4 - 446 D3 - 476 D12 - 416 D2 - 485 D15 + 324 D42 \\
 & - 381 D9 - 366 D1 + 4560 H4 + 4549 H5 - 321 D11 + 4539 \\
 & H3 - 293 D48 - 269 D10 + 4462 H2 - 334 D16 - 209 D47 + \\
 & 163 D43 + 129 D27 + 116 D28 + 56 M37 + 60 M36 + 84 M39 \\
 & + 73 M38 + 62 M40 - 118 D46 + 90 M41 + 141 M42 - 69 M35 \\
 & + 95,9 D29 - 136 D24 - 3,6 D45 + 50,1 D44 + 157 M43 \\
 & - 128 D25 + 105 D34 - 183 D17 - 86 S35 - 131 S40 - 103 \\
 & S41 - 80 S38 - 112 S39 - 95 S37
 \end{aligned}$$

**Lampiran 36. Output Time Series Regression Window 5 dengan
Variabel Preditor Hasil Seleksi Tahap 2 Random
Forest (Lanjutan).**

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	3835,24	24,01	159,72	0,000
t	-0,05025	0,01445	-3,48	0,001
H1	4204,87	20,85	201,64	0,000
H6	4277,51	23,26	183,92	0,000
D36	640,16	46,04	13,91	0,000
D37	635,91	49,84	12,76	0,000
D38	595,53	49,84	11,95	0,000
D39	590,87	49,84	11,86	0,000
D40	544,79	49,84	10,93	0,000
D35	513,56	49,84	10,30	0,000
D14	-634,02	43,03	-14,73	0,000
D13	-625,19	43,03	-14,53	0,000
D41	467,53	49,84	9,38	0,000
D7	-552,35	43,03	-12,84	0,000
D6	-547,05	43,03	-12,71	0,000
D5	-519,95	43,03	-12,08	0,000
D8	-498,17	43,03	-11,58	0,000
D4	-490,14	43,03	-11,39	0,000
D3	-446,40	43,03	-10,37	0,000
D12	-476,06	43,03	-11,06	0,000
D2	-415,63	43,03	-9,66	0,000
D15	-485,30	43,03	-11,28	0,000
D42	324,24	46,04	7,04	0,000
D9	-380,77	43,03	-8,85	0,000
D1	-366,09	43,03	-8,51	0,000
H4	4559,55	21,93	207,89	0,000
H5	4548,51	22,25	204,44	0,000
D11	-320,75	43,03	-7,45	0,000
H3	4538,94	21,63	209,81	0,000
D48	-292,88	43,03	-6,81	0,000
D10	-268,65	43,03	-6,24	0,000
H2	4461,89	21,20	210,50	0,000
D16	-334,33	43,03	-7,77	0,000
D47	-209,14	43,03	-4,86	0,000
D43	162,82	46,04	3,54	0,000
D27	129,41	43,03	3,01	0,003
D28	116,22	43,03	2,70	0,007
M37	55,6	124,2	0,45	0,654
M36	60,0	122,7	0,49	0,625
M39	84,0	124,2	0,68	0,499
M38	72,8	124,2	0,59	0,558

Lampiran 36. Output Time Series Regression Window 5 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest (Lanjutan).

M40	61,7	124,2	0,50	0,619
D46	-118,18	43,03	-2,75	0,006
M41	90,4	124,2	0,73	0,467
M42	141,2	122,7	1,15	0,250
M35	-69,5	124,2	-0,56	0,576
D29	95,88	43,03	2,23	0,026
D24	-136,38	43,03	-3,17	0,002
D45	-3,64	43,03	-0,08	0,933
D44	50,10	43,03	1,16	0,245
M43	157,4	122,7	1,28	0,200
D25	-127,56	43,03	-2,96	0,003
D34	104,57	43,03	2,43	0,015
D17	-182,60	43,03	-4,24	0,000
S35	-85,5	124,1	-0,69	0,491
S40	-130,9	124,1	-1,05	0,292
S41	-103,3	124,1	-0,83	0,405
S38	-80,3	124,1	-0,65	0,518
S39	-112,1	124,1	-0,90	0,366
S37	-94,9	124,1	-0,76	0,444

S = 225,652

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	60	26120644688	435344078	8549,74	0,000
Residual Error	1380	70268213	50919		
Total	1440	26190912901			

Lampiran 37. Output Time Series Regression Window 6 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest.

The regression equation is

$$\begin{aligned}
 Y(t) = & 3802 H7 - 0,0128 t + 4118 H1 + 4240 H6 + 637 D36 + 617 \\
 & D37 + 588 D38 + 585 D39 + 521 D40 + 512 D35 - 628 D14 - \\
 & 619 D13 + 448 D41 - 543 D7 - 538 D6 - 510 D5 - 489 D8 - \\
 & 480 D4 - 437 D3 - 471 D12 - 406 D2 - 480 D15 + 4511 H3 \\
 & + 320 D42 - 372 D9 + 4534 H4 - 356 D1 + 4521 H5 - 319 \\
 & D11 - 295 D48 + 4433 H2 - 261 D10 - 332 D16 - 213 D47 + \\
 & 158 D43 + 130 D27 + 65 M36 + 76 M37 + 92 M39 + 82 M38 + \\
 & 113 D28 + 87 M40 - 121 D46 + 111 M41 + 147 M42 - 66 M35 \\
 & + 95,0 D29 - 139 D24 - 7,5 D45 + 45,3 D44 + 164 M43 - \\
 & 129 D25 - 182 D17 - 76 S35 + 102 D34 - 66 S38 - 99 S39
 \end{aligned}$$

**Lampiran 37. Output Time Series Regression Window 6 dengan
Variabel Preditor Hasil Seleksi Tahap 2 Random
Forest (Lanjutan).**

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	3801,78	22,96	165,58	0,000
t	-0,01277	0,01401	-0,91	0,362
H1	4117,66	22,22	185,28	0,000
H6	4240,41	21,87	193,85	0,000
D36	636,52	44,64	14,26	0,000
D37	617,08	44,64	13,82	0,000
D38	588,06	48,32	12,17	0,000
D39	584,67	48,32	12,10	0,000
D40	520,96	44,64	11,67	0,000
D35	511,55	48,32	10,59	0,000
D14	-627,75	41,73	-15,04	0,000
D13	-619,33	41,73	-14,84	0,000
D41	448,31	44,64	10,04	0,000
D7	-543,22	41,73	-13,02	0,000
D6	-537,94	41,73	-12,89	0,000
D5	-510,10	41,73	-12,22	0,000
D8	-488,95	41,73	-11,72	0,000
D4	-479,91	41,73	-11,50	0,000
D3	-436,53	41,73	-10,46	0,000
D12	-471,11	41,73	-11,29	0,000
D2	-405,79	41,73	-9,72	0,000
D15	-480,38	41,73	-11,51	0,000
H3	4511,10	20,54	219,61	0,000
D42	320,31	44,64	7,18	0,000
D9	-371,94	41,73	-8,91	0,000
H4	4533,69	20,97	216,25	0,000
D1	-356,35	41,73	-8,54	0,000
H5	4520,85	21,25	212,70	0,000
D11	-319,34	41,73	-7,65	0,000
D48	-295,27	41,73	-7,08	0,000
H2	4433,32	20,21	219,39	0,000
D10	-260,77	41,73	-6,25	0,000
D16	-332,14	41,73	-7,96	0,000
D47	-212,76	41,73	-5,10	0,000
D43	157,82	44,64	3,54	0,000
D27	129,90	41,73	3,11	0,002
M36	65,4	119,0	0,55	0,583
M37	76,2	119,0	0,64	0,522
M39	91,9	120,4	0,76	0,445
M38	82,0	120,4	0,68	0,496
D28	113,10	41,73	2,71	0,007

Lampiran 37. Output Time Series Regression Window 6 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest (Lanjutan).

M40	87,2	119,0	0,73	0,464
D46	-121,03	41,73	-2,90	0,004
M41	111,3	119,0	0,93	0,350
M42	146,7	119,0	1,23	0,218
M35	-65,6	120,4	-0,54	0,586
D29	95,03	41,73	2,28	0,023
D24	-139,15	41,73	-3,33	0,001
D45	-7,49	41,73	-0,18	0,858
D44	45,26	41,73	1,08	0,278
M43	163,9	119,0	1,38	0,169
D25	-128,96	41,73	-3,09	0,002
D17	-181,70	41,73	-4,35	0,000
S35	-76,2	120,3	-0,63	0,526
D34	102,06	41,73	2,45	0,015
S38	-65,6	120,3	-0,55	0,585
S39	-98,8	120,3	-0,82	0,412

S = 218,811

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	57	26144586108	458676949	9580,09	0,000
Residual Error	1383	66215483	47878		
Total	1440	26210801592			

Lampiran 38. Output Time Series Regression Window 7 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest.

The regression equation is

$$\begin{aligned}
 Y(t) = & 3794 H7 - 0,0025 t + 4110 H1 + 4230 H6 + 636 D36 + 617 \\
 & D37 + 578 D38 + 568 D39 + 521 D40 + 516 D35 - 629 D14 - \\
 & 622 D13 + 449 D41 - 544 D7 - 539 D6 + 4524 H4 - 510 D5 \\
 & - 488 D8 - 479 D4 + 4504 H3 + 4514 H5 - 475 D12 - 437 \\
 & D3 - 408 D2 - 480 D15 + 320 D42 - 371 D9 - 358 D1 \\
 & - 323 D11 - 294 D48 + 4407 H2 - 260 D10 - 332 D16 - 212 \\
 & D47 + 158 D43 + 129 D27 + 66 M36 + 76 M37 + 92 M38 + \\
 & 108 M39 + 87 M40 - 120 D46 + 112 D28 + 110 M41 + 147 \\
 & M42 - 70 M35 + 94,8 D29 - 136 D24 - 6,1 D45 + 46,7 D44 \\
 & + 164 M43 - 182 D17 - 128 D25 - 78 S35 + 104 D34
 \end{aligned}$$

Lampiran 38. *Output Time Series Regression Window 7 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest (Lanjutan).*

Predictor	Coef	SE Coef	T	P
Noconstant				
H7	3793,97	22,60	167,90	0,000
t	-0,00254	0,01398	-0,18	0,856
H1	4109,77	21,82	188,32	0,000
H6	4230,11	21,30	198,63	0,000
D36	635,89	44,53	14,28	0,000
D37	617,33	44,53	13,86	0,000
D38	577,69	44,53	12,97	0,000
D39	568,45	44,53	12,77	0,000
D40	520,83	44,53	11,70	0,000
D35	515,86	48,20	10,70	0,000
D14	-629,27	41,62	-15,12	0,000
D13	-621,87	41,62	-14,94	0,000
D41	448,76	44,53	10,08	0,000
D7	-543,72	41,62	-13,06	0,000
D6	-539,03	41,62	-12,95	0,000
H4	4523,84	20,48	220,86	0,000
D5	-510,13	41,62	-12,26	0,000
D8	-487,51	41,62	-11,71	0,000
D4	-479,45	41,62	-11,52	0,000
H3	4503,94	20,15	223,52	0,000
H5	4514,43	20,91	215,94	0,000
D12	-474,73	41,62	-11,41	0,000
D3	-437,00	41,62	-10,50	0,000
D2	-408,15	41,62	-9,81	0,000
D15	-480,23	41,62	-11,54	0,000
D42	320,19	44,53	7,19	0,000
D9	-370,95	41,62	-8,91	0,000
D1	-357,56	41,62	-8,59	0,000
D11	-322,92	41,62	-7,76	0,000
D48	-294,01	41,62	-7,06	0,000
H2	4407,28	22,16	198,87	0,000
D10	-260,34	41,62	-6,25	0,000
D16	-332,24	41,62	-7,98	0,000
D47	-212,36	41,62	-5,10	0,000
D43	157,71	44,53	3,54	0,000
D27	129,27	41,62	3,11	0,002
M36	65,8	118,7	0,55	0,580
M37	75,7	118,7	0,64	0,524
M38	92,1	118,7	0,78	0,438
M39	107,8	118,7	0,91	0,364
M40	87,0	118,7	0,73	0,464

Lampiran 38. *Output Time Series Regression Window 7 dengan Variabel Preditor Hasil Seleksi Tahap 2 Random Forest (Lanjutan).*

D46	-119,94	41,62	-2,88	0,004
D28	111,99	41,62	2,69	0,007
M41	110,5	118,7	0,93	0,352
M42	146,5	118,7	1,23	0,217
M35	-70,2	120,1	-0,58	0,559
D29	94,78	41,62	2,28	0,023
D24	-136,45	41,62	-3,28	0,001
D45	-6,06	41,62	-0,15	0,884
D44	46,66	41,62	1,12	0,263
M43	163,7	118,7	1,38	0,168
D17	-182,38	41,62	-4,38	0,000
D25	-127,81	41,62	-3,07	0,002
S35	-77,8	119,9	-0,65	0,516
D34	103,59	41,62	2,49	0,013


S = 218,268







Analysis of Variance

Source	DF	SS	MS	F	P
Regression	55	26145446191	475371749	9978,20	0,000
Residual Error	1385	65982811	47641		
Total	1440	26211429002			



Lampiran 39. *Normality Test dan ACF Residual Window 1-7 Model Time Series Regression dengan 59 Variabel Preditor.*

a. *Window 1*





b. *Window 2*c. *Window 3*d. *Window 4*



e. Window 5



f. Window 6



g. Window 7



Lampiran 40. Variabel Terpilih Di Setiap *Window* pada Model *Time Series Regression* Hasil Seleksi Tahap 2 *Random Forest*.

No	Variabel	Window							Jumlah
		1	2	3	4	5	6	7	
1	t	1	1	1	1	1	1	1	7
2	D1	1	1	1	1	1	1	1	7
3	D2	1	1	1	1	1	1	1	7
4	D3	1	1	1	1	1	1	1	7
5	D4	1	1	1	1	1	1	1	7
6	D5	1	1	1	1	1	1	1	7
7	D6	1	1	1	1	1	1	1	7
8	D7	1	1	1	1	1	1	1	7
9	D8	1	1	1	1	1	1	1	7
10	D9	1	1	1	1	1	1	1	7
11	D10	1	1	1	1	1	1	1	7
12	D11	1	1	1	1	1	1	1	7
13	D12	1	1	1	1	1	1	1	7
14	D13	1	1	1	1	1	1	1	7
15	D14	1	1	1	1	1	1	1	7
16	D15	1	1	1	1	1	1	1	7
17	D16	1	1	1	1	1	1	1	7
18	D17	0	0	0	1	1	1	1	4
19	D18	0	0	0	0	0	0	0	0
20	D19	0	0	0	0	0	0	0	0
21	D20	0	0	0	0	0	0	0	0
22	D21	0	0	0	0	0	0	0	0
23	D22	0	0	0	0	0	0	0	0
24	D23	0	0	0	0	0	0	0	0
25	D24	1	1	1	1	1	1	1	7

Lampiran 40. Variabel Terpilih Di Setiap *Window* pada Model *Time Series Regression* Hasil Seleksi Tahap 2 *Random Forest* (Lanjutan).

No	Variabel	Window							Jumlah
		1	2	3	4	5	6	7	
26	D25	1	1	1	1	1	1	1	7
27	D26	0	0	0	0	0	0	0	0
28	D27	1	1	1	1	1	1	1	7
29	D28	1	1	1	1	1	1	1	7
30	D29	1	1	1	1	1	1	1	7
31	D30	1	1	0	1	0	0	0	3
32	D31	0	0	0	0	0	0	0	0
33	D32	0	0	0	0	0	0	0	0
34	D33	0	0	0	0	0	0	0	0
35	D34	1	1	1	1	1	1	1	7
36	D35	1	1	1	1	1	1	1	7
37	D36	1	1	1	1	1	1	1	7
38	D37	1	1	1	1	1	1	1	7
39	D38	1	1	1	1	1	1	1	7
40	D39	1	1	1	1	1	1	1	7
41	D40	1	1	1	1	1	1	1	7
42	D41	1	1	1	1	1	1	1	7
43	D42	1	1	1	1	1	1	1	7
44	D43	1	1	1	1	1	1	1	7
45	D44	1	1	1	1	1	1	1	7
46	D45	1	1	1	1	1	1	1	7
47	D46	1	1	1	1	1	1	1	7
48	D47	1	1	1	1	1	1	1	7
49	D48	1	1	1	1	1	1	1	7
50	H1	1	1	1	1	1	1	1	7
51	H2	1	1	1	1	1	1	1	7

Lampiran 40. Variabel Terpilih Di Setiap *Window* pada Model *Time Series Regression* Hasil Seleksi Tahap 2 *Random Forest* (Lanjutan).

No	Variabel	Window							Jumlah
		1	2	3	4	5	6	7	
52	H3	1	1	1	1	1	1	1	7
53	H4	1	1	1	1	1	1	1	7
54	H5	1	1	1	1	1	1	1	7
55	H6	1	1	1	1	1	1	1	7
56	H7	1	1	1	1	1	1	1	7
57	J1	0	0	0	0	0	0	0	0
58	J2	0	0	0	0	0	0	0	0
59	J3	0	0	0	0	0	0	0	0
60	J4	0	0	0	0	0	0	0	0
61	J5	0	0	0	0	0	0	0	0
62	S1	0	0	0	0	0	0	0	0
63	S2	0	0	0	0	0	0	0	0
64	S3	0	0	0	0	0	0	0	0
65	S4	0	0	0	0	0	0	0	0
66	S5	0	0	0	0	0	0	0	0
67	S6	0	0	0	0	0	0	0	0
68	S7	0	0	0	0	0	0	0	0
69	S8	0	0	0	0	0	0	0	0
70	S9	0	0	0	0	0	0	0	0
71	S10	0	0	0	0	0	0	0	0
72	S11	0	0	0	0	0	0	0	0
73	S12	0	0	0	0	0	0	0	0
74	S13	0	1	0	0	0	0	0	1
75	S14	0	1	0	0	0	0	0	1
76	S15	0	1	0	0	0	0	0	1
77	S16	0	0	0	0	0	0	0	0

Lampiran 40. Variabel Terpilih Di Setiap *Window* pada Model *Time Series Regression* Hasil Seleksi Tahap 2 *Random Forest* (Lanjutan).

No	Variabel	Window							Jumlah
		1	2	3	4	5	6	7	
78	S17	0	0	0	0	0	0	0	0
79	S18	0	0	0	0	0	0	0	0
80	S19	0	0	0	0	0	0	0	0
81	S20	0	0	0	0	0	0	0	0
82	S21	0	0	0	0	0	0	0	0
83	S22	0	0	0	0	0	0	0	0
84	S23	0	0	0	0	0	0	0	0
85	S24	0	0	0	0	0	0	0	0
86	S25	0	0	0	0	0	0	0	0
87	S26	0	0	0	0	0	0	0	0
88	S27	0	0	0	0	0	0	0	0
89	S28	0	0	0	0	0	0	0	0
90	S29	0	0	0	0	0	0	0	0
91	S30	0	0	0	0	0	0	0	0
92	S31	0	0	0	0	0	0	0	0
93	S32	0	0	0	0	0	0	0	0
94	S33	0	0	0	0	0	0	0	0
95	S34	0	0	0	0	0	0	0	0
96	S35	1	1	1	1	1	1	1	7
97	S36	0	1	1	1	0	0	0	3
98	S37	1	1	1	1	1	0	0	5
99	S38	1	1	1	1	1	1	0	6
100	S39	1	1	1	1	1	1	0	6
101	S40	1	1	1	1	1	0	0	5
102	S41	1	1	1	1	1	0	0	5
103	S42	0	1	1	0	0	0	0	2

Lampiran 40. Variabel Terpilih Di Setiap *Window* pada Model *Time Series Regression* Hasil Seleksi Tahap 2 *Random Forest* (Lanjutan).

No	Variabel	Window							Jumlah
		1	2	3	4	5	6	7	
104	S43	0	0	0	0	0	0	0	0
105	S44	0	0	0	0	0	0	0	0
106	S45	0	0	0	0	0	0	0	0
107	S46	0	0	0	0	0	0	0	0
108	S47	0	0	0	0	0	0	0	0
109	S48	0	0	0	0	0	0	0	0
110	M1	0	0	0	0	0	0	0	0
111	M2	0	0	0	0	0	0	0	0
112	M3	0	0	0	0	0	0	0	0
113	M4	0	0	0	0	0	0	0	0
114	M5	0	0	0	0	0	0	0	0
115	M6	0	0	0	0	0	0	0	0
116	M7	0	0	0	0	0	0	0	0
117	M8	0	0	0	0	0	0	0	0
118	M9	0	0	0	0	0	0	0	0
119	M10	0	0	0	0	0	0	0	0
120	M11	0	0	0	0	0	0	0	0
121	M12	0	0	0	0	0	0	0	0
122	M13	0	0	0	0	0	0	0	0
123	M14	0	0	0	0	0	0	0	0
124	M15	0	0	0	0	0	0	0	0
125	M16	0	0	0	0	0	0	0	0
126	M17	0	0	0	0	0	0	0	0
127	M18	0	0	0	0	0	0	0	0
128	M19	0	0	0	0	0	0	0	0
129	M20	0	0	0	0	0	0	0	0

Lampiran 40. Variabel Terpilih Di Setiap *Window* pada Model *Time Series Regression* Hasil Seleksi Tahap 2 *Random Forest* (Lanjutan).

No	Variabel	Window							Jumlah
		1	2	3	4	5	6	7	
130	M21	0	0	0	0	0	0	0	0
131	M22	0	0	0	0	0	0	0	0
132	M23	0	0	0	0	0	0	0	0
133	M24	0	0	0	0	0	0	0	0
134	M25	0	0	0	0	0	0	0	0
135	M26	0	0	0	0	0	0	0	0
136	M27	0	0	0	0	0	0	0	0
137	M28	0	0	0	0	0	0	0	0
138	M29	0	0	0	0	0	0	0	0
139	M30	0	0	0	0	0	0	0	0
140	M31	0	0	0	0	0	0	0	0
141	M32	0	0	0	0	0	0	0	0
142	M33	0	0	0	0	0	0	0	0
143	M34	0	0	0	0	0	0	0	0
144	M35	1	1	1	1	1	1	1	7
145	M36	1	1	1	1	1	1	1	7
146	M37	1	1	1	1	1	1	1	7
147	M38	1	1	1	1	1	1	1	7
148	M39	1	1	1	1	1	1	1	7
149	M40	1	1	1	1	1	1	1	7
150	M41	1	1	1	1	1	1	1	7
151	M42	1	1	1	1	1	1	1	7
152	M43	1	1	1	1	1	1	1	7
153	M44	0	1	1	1	0	0	0	3
154	M45	0	0	0	1	0	0	0	1
155	M46	0	0	0	0	0	0	0	0

Lampiran 40. Variabel Terpilih Di Setiap *Window* pada Model *Time Series Regression* Hasil Seleksi Tahap 2 *Random Forest* (Lanjutan).

No	Variabel	Window							Jumlah
		1	2	3	4	5	6	7	
156	M47	0	0	0	0	0	0	0	0
157	M48	0	0	0	0	0	0	0	0

Lampiran 41. *Output Time Series Regression Window 1* dengan 59 Variabel Preditor.

The regression equation is

$$Y(t) = -0,0088 t - 333 D1 - 380 D2 - 412 D3 - 453 D4 - 486 D5 - 517 D6 - 518 D7 - 469 D8 - 351 D9 - 234 D10 - 282 D11 - 440 D12 - 593 D13 - 608 D14 - 460 D15 - 312 D16 - 127 D24 - 110 D25 + 155 D27 + 135 D28 + 109 D29 + 111 D34 + 519 D35 + 662 D36 + 651 D37 + 614 D38 + 603 D39 + 556 D40 + 484 D41 + 346 D42 + 189 D43 + 76,9 D44 + 17,2 D45 - 94,7 D46 - 185 D47 - 271 D48 + 4143 H1 + 4427 H2 + 4493 H3 + 4485 H4 + 4482 H5 + 4240 H6 + 3809 H7 - 90 S35 - 74 S37 - 68 S38 - 94 S39 - 103 S40 - 88 S41 - 61 M35 + 64 M36 + 65 M37 + 69 M38 + 86 M39 + 78 M40 + 110 M41 + 154 M42 + 172 M43$$

Predictor	Coef	SE Coef	T	P
Noconstant				
t	-0,00885	0,01443	-0,61	0,540
D1	-333,39	42,83	-7,78	0,000
D2	-379,95	42,83	-8,87	0,000
D3	-411,93	42,83	-9,62	0,000
D4	-453,35	42,83	-10,59	0,000
D5	-486,31	42,83	-11,36	0,000
D6	-516,58	42,82	-12,06	0,000
D7	-518,05	42,82	-12,10	0,000
D8	-469,31	42,82	-10,96	0,000
D9	-350,95	42,82	-8,20	0,000
D10	-233,70	42,82	-5,46	0,000
D11	-282,36	42,82	-6,59	0,000
D12	-439,95	42,82	-10,27	0,000
D13	-593,16	42,82	-13,85	0,000
D14	-607,51	42,82	-14,19	0,000
D15	-460,25	42,82	-10,75	0,000
D16	-312,45	42,82	-7,30	0,000

Lampiran 41. *Output Time Series Regression Window 1 dengan 59 Variabel Preditor (Lanjutan).*

D24	-126,87	42,82	-2,96	0,003
D25	-110,36	42,82	-2,58	0,010
D27	154,92	42,82	3,62	0,000
D28	134,56	42,82	3,14	0,002
D29	109,28	42,82	2,55	0,011
D34	110,62	42,82	2,58	0,010
D35	519,02	49,65	10,45	0,000
D36	661,96	45,84	14,44	0,000
D37	651,11	49,65	13,12	0,000
D38	613,83	49,65	12,36	0,000
D39	603,30	49,65	12,15	0,000
D40	555,92	49,65	11,20	0,000
D41	484,30	49,65	9,76	0,000
D42	345,93	45,84	7,55	0,000
D43	188,84	45,84	4,12	0,000
D44	76,91	42,83	1,80	0,073
D45	17,24	42,83	0,40	0,687
D46	-94,68	42,83	-2,21	0,027
D47	-184,81	42,83	-4,32	0,000
D48	-271,26	42,83	-6,33	0,000
H1	4142,94	21,92	188,97	0,000
H2	4427,26	22,26	198,88	0,000
H3	4492,90	22,61	198,68	0,000
H4	4485,17	20,51	218,67	0,000
H5	4482,22	20,86	214,88	0,000
H6	4239,82	22,02	192,58	0,000
H7	3808,69	22,75	167,45	0,000
S35	-89,7	123,9	-0,72	0,469
S37	-74,4	123,9	-0,60	0,548
S38	-68,4	123,9	-0,55	0,581
S39	-93,9	123,9	-0,76	0,449
S40	-103,4	123,9	-0,83	0,404
S41	-88,4	123,9	-0,71	0,476
M35	-61,1	124,1	-0,49	0,622
M36	64,3	122,6	0,52	0,600
M37	64,6	124,1	0,52	0,602
M38	69,4	124,1	0,56	0,576
M39	85,8	124,1	0,69	0,489
M40	77,6	124,1	0,63	0,531
M41	109,7	124,1	0,88	0,377
M42	153,7	122,6	1,25	0,210
M43	172,1	122,6	1,40	0,161

Lampiran 41. *Output Time Series Regression Window 1 dengan 59 Variabel Preditor (Lanjutan).*

S = 225,356

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	59	26301890881	445794761	8778,05	0,000
Residual Error	1381	70134321	50785		
Total	1440	26372025202			

Lampiran 42. *Output Time Series Regression Window 2 dengan 59 Variabel Preditor.*

The regression equation is

$$Y(t) = - 0,0366 t - 324 D1 - 371 D2 - 404 D3 - 445 D4 - 475 D5 - 506 D6 - 508 D7 - 459 D8 - 341 D9 - 226 D10 - 277 D11 - 435 D12 - 586 D13 - 603 D14 - 456 D15 - 311 D16 - 123 D24 - 111 D25 + 145 D27 + 127 D28 + 103 D29 + 112 D34 + 523 D35 + 662 D36 + 657 D37 + 616 D38 + 610 D39 + 563 D40 + 491 D41 + 345 D42 + 185 D43 + 74,3 D44 + 16,3 D45 - 96,0 D46 - 187 D47 - 272 D48 + 4159 H1 + 4444 H2 + 4511 H3 + 4531 H4 + 4499 H5 + 4244 H6 + 3823 H7 - 85 S35 - 87 S37 - 77 S38 - 110 S39 - 130 S40 - 105 S41 - 62 M35 + 67 M36 + 62 M37 + 70 M38 + 82 M39 + 74 M40 + 106 M41 + 158 M42 + 179 M43$$

Predictor	Coef	SE Coef	T	P
Noconstant				
t	-0,03655	0,01445	-2,53	0,012
D1	-323,50	42,88	-7,54	0,000
D2	-370,85	42,88	-8,65	0,000
D3	-404,17	42,88	-9,43	0,000
D4	-445,09	42,88	-10,38	0,000
D5	-475,12	42,88	-11,08	0,000
D6	-505,51	42,88	-11,79	0,000
D7	-508,25	42,88	-11,85	0,000
D8	-459,17	42,88	-10,71	0,000
D9	-341,33	42,88	-7,96	0,000
D10	-226,00	42,88	-5,27	0,000
D11	-276,87	42,88	-6,46	0,000
D12	-435,01	42,88	-10,14	0,000
D13	-586,18	42,88	-13,67	0,000
D14	-603,24	42,88	-14,07	0,000
D15	-456,18	42,88	-10,64	0,000
D16	-311,16	42,88	-7,26	0,000

**Lampiran 42. Output Time Series Regression Window 2 dengan
59 Variabel Preditor (Lanjutan).**

D24	-122,63	42,88	-2,86	0,004
D25	-110,81	42,88	-2,58	0,010
D27	144,89	42,88	3,38	0,001
D28	126,57	42,88	2,95	0,003
D29	103,12	42,88	2,40	0,016
D34	112,16	42,88	2,62	0,009
D35	523,00	50,83	10,29	0,000
D36	662,01	45,90	14,42	0,000
D37	656,74	50,83	12,92	0,000
D38	616,20	50,83	12,12	0,000
D39	609,82	50,83	12,00	0,000
D40	563,02	50,83	11,08	0,000
D41	490,80	50,83	9,66	0,000
D42	344,55	45,90	7,51	0,000
D43	185,16	45,90	4,03	0,000
D44	74,34	42,88	1,73	0,083
D45	16,31	42,88	0,38	0,704
D46	-95,95	42,88	-2,24	0,025
D47	-186,91	42,88	-4,36	0,000
D48	-271,75	42,88	-6,34	0,000
H1	4158,60	21,64	192,17	0,000
H2	4444,25	21,96	202,37	0,000
H3	4511,22	22,30	202,32	0,000
H4	4531,18	22,65	200,04	0,000
H5	4498,54	20,55	218,95	0,000
H6	4243,53	21,44	197,93	0,000
H7	3823,03	22,49	170,00	0,000
S35	-84,7	113,6	-0,75	0,456
S37	-86,6	113,6	-0,76	0,446
S38	-77,4	113,6	-0,68	0,496
S39	-110,2	113,6	-0,97	0,332
S40	-129,6	113,6	-1,14	0,254
S41	-104,9	113,6	-0,92	0,356
M35	-62,2	124,7	-0,50	0,618
M36	67,1	122,7	0,55	0,585
M37	61,9	124,7	0,50	0,620
M38	70,0	124,7	0,56	0,575
M39	82,2	124,7	0,66	0,510
M40	73,5	124,7	0,59	0,555
M41	106,2	124,7	0,85	0,394
M42	158,1	122,7	1,29	0,198
M43	178,8	122,7	1,46	0,145

Lampiran 42. *Output Time Series Regression Window 2 dengan 59 Variabel Preditor (Lanjutan).*

S = 225,654

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	59	26201921985	444100373	8721,58	0,000
Residual Error	1381	70320105	50920		
Total	1440	26272242090			

Lampiran 43. *Output Time Series Regression Window 3 dengan 59 Variabel Preditor.*

The regression equation is

$$Y(t) = -0,0574 t - 301 D1 - 347 D2 - 381 D3 - 423 D4 - 452 D5 - 482 D6 - 485 D7 - 436 D8 - 321 D9 - 209 D10 - 260 D11 - 417 D12 - 570 D13 - 588 D14 - 447 D15 - 304 D16 - 114 D24 - 104 D25 + 137 D27 + 121 D28 + 97,9 D29 + 122 D34 + 538 D35 + 673 D36 + 670 D37 + 628 D38 + 621 D39 + 579 D40 + 503 D41 + 356 D42 + 198 D43 + 90,7 D44 + 33,7 D45 - 78,3 D46 - 169 D47 - 253 D48 + 4159 H1 + 4446 H2 + 4514 H3 + 4535 H4 + 4524 H5 + 4246 H6 + 3816 H7 - 89 S35 - 89 S37 - 78 S38 - 111 S39 - 134 S40 - 107 S41 - 39 M35 + 67 M36 + 62 M37 + 80 M38 + 86 M39 + 70 M40 + 96 M41 + 146 M42 + 162 M43$$

Predictor	Coef	SE Coef	T	P
Noconstant				
t	-0,05743	0,01463	-3,93	0,000
D1	-300,64	43,41	-6,93	0,000
D2	-347,47	43,41	-8,00	0,000
D3	-381,14	43,41	-8,78	0,000
D4	-423,29	43,41	-9,75	0,000
D5	-452,29	43,41	-10,42	0,000
D6	-482,12	43,41	-11,11	0,000
D7	-485,25	43,41	-11,18	0,000
D8	-435,93	43,41	-10,04	0,000
D9	-321,39	43,41	-7,40	0,000
D10	-208,54	43,41	-4,80	0,000
D11	-260,30	43,41	-6,00	0,000
D12	-417,17	43,41	-9,61	0,000
D13	-569,96	43,41	-13,13	0,000
D14	-587,66	43,41	-13,54	0,000
D15	-447,25	43,41	-10,30	0,000
D16	-304,24	43,41	-7,01	0,000

**Lampiran 43. Output Time Series Regression Window 3 dengan
59 Variabel Preditor (Lanjutan).**

D24	-114,00	43,41	-2,63	0,009
D25	-103,64	43,41	-2,39	0,017
D27	137,02	43,41	3,16	0,002
D28	121,00	43,41	2,79	0,005
D29	97,90	43,41	2,26	0,024
D34	122,41	43,41	2,82	0,005
D35	537,71	52,68	10,21	0,000
D36	672,74	47,34	14,21	0,000
D37	669,56	52,68	12,71	0,000
D38	627,57	52,68	11,91	0,000
D39	621,19	52,68	11,79	0,000
D40	578,58	52,68	10,98	0,000
D41	503,40	52,68	9,55	0,000
D42	355,69	47,34	7,51	0,000
D43	198,01	47,34	4,18	0,000
D44	90,68	43,41	2,09	0,037
D45	33,72	43,41	0,78	0,437
D46	-78,31	43,41	-1,80	0,071
D47	-169,07	43,41	-3,89	0,000
D48	-253,01	43,41	-5,83	0,000
H1	4159,22	21,61	192,43	0,000
H2	4445,88	21,92	202,82	0,000
H3	4513,85	22,24	202,93	0,000
H4	4534,81	22,59	200,79	0,000
H5	4524,12	22,94	197,19	0,000
H6	4245,96	21,36	198,74	0,000
H7	3815,62	22,06	172,98	0,000
S35	-88,8	115,6	-0,77	0,442
S37	-88,8	115,6	-0,77	0,442
S38	-78,1	115,6	-0,68	0,499
S39	-111,0	115,6	-0,96	0,337
S40	-134,5	115,6	-1,16	0,245
S41	-106,8	115,6	-0,92	0,356
M35	-38,7	115,7	-0,33	0,738
M36	67,4	113,3	0,59	0,552
M37	61,9	115,7	0,53	0,593
M38	79,9	115,7	0,69	0,490
M39	86,4	115,7	0,75	0,455
M40	69,8	115,7	0,60	0,546
M41	96,4	115,7	0,83	0,405
M42	146,5	113,3	1,29	0,196
M43	161,7	113,3	1,43	0,154

Lampiran 43. *Output Time Series Regression Window 3 dengan 59 Variabel Preditor (Lanjutan).*

S = 228,444

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	59	25935944714	439592283	8423,48	0,000
Residual Error	1381	72069644	52187		
Total	1440	26008014358			

Lampiran 44. *Output Time Series Regression Window 4 dengan 59 Variabel Preditor.*

The regression equation is

$$Y(t) = -0,0484 t - 324 D1 - 373 D2 - 404 D3 - 447 D4 - 478 D5 - 505 D6 - 510 D7 - 458 D8 - 342 D9 - 231 D10 - 283 D11 - 438 D12 - 588 D13 - 601 D14 - 459 D15 - 314 D16 - 119 D24 - 108 D25 + 139 D27 + 126 D28 + 107 D29 + 125 D34 + 534 D35 + 666 D36 + 661 D37 + 620 D38 + 612 D39 + 569 D40 + 494 D41 + 350 D42 + 189 D43 + 81,2 D44 + 27,0 D45 - 85,3 D46 - 175 D47 - 259 D48 + 4180 H1 + 4446 H2 + 4514 H3 + 4534 H4 + 4523 H5 + 4252 H6 + 3816 H7 - 79 S35 - 93 S37 - 78 S38 - 107 S39 - 128 S40 - 103 S41 - 44 M35 + 65 M36 + 62 M37 + 78 M38 + 86 M39 + 70 M40 + 97 M41 + 143 M42 + 161 M43$$

Predictor	Coef	SE Coef	T	P
Noconstant				
t	-0,04842	0,01476	-3,28	0,001
D1	-324,01	43,82	-7,39	0,000
D2	-372,74	43,82	-8,51	0,000
D3	-404,24	43,82	-9,23	0,000
D4	-447,48	43,82	-10,21	0,000
D5	-477,51	43,82	-10,90	0,000
D6	-504,81	43,82	-11,52	0,000
D7	-509,69	43,82	-11,63	0,000
D8	-457,71	43,82	-10,45	0,000
D9	-342,37	43,82	-7,81	0,000
D10	-230,66	43,82	-5,26	0,000
D11	-282,81	43,82	-6,45	0,000
D12	-438,03	43,82	-10,00	0,000
D13	-588,04	43,82	-13,42	0,000
D14	-600,98	43,82	-13,72	0,000
D15	-458,75	43,82	-10,47	0,000
D16	-313,74	43,82	-7,16	0,000

Lampiran 44. *Output Time Series Regression Window 4 dengan 59 Variabel Preditor (Lanjutan).*

D24	-119,01	43,82	-2,72	0,007
D25	-108,42	43,82	-2,47	0,013
D27	138,97	43,82	3,17	0,002
D28	126,29	43,82	2,88	0,004
D29	107,06	43,82	2,44	0,015
D34	124,75	43,82	2,85	0,004
D35	533,90	51,94	10,28	0,000
D36	665,96	47,78	13,94	0,000
D37	660,52	51,94	12,72	0,000
D38	619,98	51,94	11,94	0,000
D39	611,94	51,94	11,78	0,000
D40	568,67	51,94	10,95	0,000
D41	493,63	51,94	9,50	0,000
D42	349,91	47,78	7,32	0,000
D43	189,48	47,78	3,97	0,000
D44	81,18	43,82	1,85	0,064
D45	27,01	43,82	0,62	0,538
D46	-85,34	43,82	-1,95	0,052
D47	-175,13	43,82	-4,00	0,000
D48	-258,93	43,82	-5,91	0,000
H1	4179,70	21,35	195,74	0,000
H2	4446,36	21,81	203,90	0,000
H3	4513,90	22,12	204,10	0,000
H4	4534,43	22,44	202,04	0,000
H5	4523,30	22,79	198,50	0,000
H6	4251,81	23,83	178,42	0,000
H7	3815,73	21,92	174,06	0,000
S35	-79,3	127,3	-0,62	0,534
S37	-92,9	127,3	-0,73	0,465
S38	-78,1	127,3	-0,61	0,539
S39	-106,6	127,3	-0,84	0,402
S40	-128,2	127,3	-1,01	0,314
S41	-102,8	127,3	-0,81	0,419
M35	-44,1	116,2	-0,38	0,704
M36	64,9	114,4	0,57	0,571
M37	61,7	116,2	0,53	0,596
M38	78,2	116,2	0,67	0,501
M39	86,4	116,2	0,74	0,457
M40	70,5	116,2	0,61	0,544
M41	96,9	116,2	0,83	0,405
M42	143,0	114,4	1,25	0,212
M43	161,0	114,4	1,41	0,160

Lampiran 44. *Output Time Series Regression Window 4 dengan 59 Variabel Preditor (Lanjutan).*

S = 230,573					
Analysis of Variance					
Source	DF	SS	MS	F	P
Regression	59	25932937487	439541313	8267,64	0,000
Residual Error	1381	73419562	53164		
Total	1440	26006357049			

Lampiran 45. *Output Time Series Regression Window 5 dengan 59 Variabel Preditor.*

The regression equation is					
Y(t) = - 0,0501 t - 351 D1 - 400 D2 - 431 D3 - 475 D4 - 505 D5 - 532 D6 - 537 D7 - 483 D8 - 366 D9 - 253 D10 - 306 D11 - 461 D12 - 610 D13 - 619 D14 - 470 D15 - 319 D16 - 121 D24 - 112 D25 + 145 D27 + 131 D28 + 111 D29 + 120 D34 + 529 D35 + 655 D36 + 651 D37 + 611 D38 + 606 D39 + 560 D40 + 483 D41 + 339 D42 + 178 D43 + 65,3 D44 + 11,6 D45 - 103 D46 - 194 D47 - 278 D48 + 4190 H1 + 4447 H2 + 4524 H3 + 4544 H4 + 4533 H5 + 4262 H6 + 3820 H7 - 86 S35 - 95 S37 - 80 S38 - 112 S39 - 131 S40 - 103 S41 - 69 M35 + 60 M36 + 56 M37 + 73 M38 + 84 M39 + 62 M40 + 90 M41 + 141 M42 + 157 M43					
Predictor	Coef	SE Coef	T	P	
Noconstant					
t	-0,05008	0,01454	-3,44	0,001	
D1	-350,87	43,15	-8,13	0,000	
D2	-400,41	43,14	-9,28	0,000	
D3	-431,18	43,14	-9,99	0,000	
D4	-474,92	43,14	-11,01	0,000	
D5	-504,73	43,14	-11,70	0,000	
D6	-531,83	43,14	-12,33	0,000	
D7	-537,13	43,14	-12,45	0,000	
D8	-482,95	43,14	-11,19	0,000	
D9	-365,55	43,14	-8,47	0,000	
D10	-253,43	43,14	-5,87	0,000	
D11	-305,53	43,14	-7,08	0,000	
D12	-460,84	43,14	-10,68	0,000	
D13	-609,98	43,14	-14,14	0,000	
D14	-618,80	43,14	-14,34	0,000	
D15	-470,08	43,14	-10,90	0,000	
D16	-319,11	43,14	-7,40	0,000	

**Lampiran 45. Output Time Series Regression Window 5 dengan
59 Variabel Preditor (Lanjutan).**

D24	-121,16	43,14	-2,81	0,005
D25	-112,34	43,14	-2,60	0,009
D27	144,62	43,14	3,35	0,001
D28	131,43	43,14	3,05	0,002
D29	111,09	43,14	2,57	0,010
D34	119,79	43,14	2,78	0,006
D35	528,77	50,02	10,57	0,000
D36	655,37	46,18	14,19	0,000
D37	651,12	50,02	13,02	0,000
D38	610,75	50,02	12,21	0,000
D39	606,08	50,02	12,12	0,000
D40	560,01	50,02	11,20	0,000
D41	482,74	50,02	9,65	0,000
D42	339,45	46,18	7,35	0,000
D43	178,03	46,18	3,86	0,000
D44	65,31	43,14	1,51	0,130
D45	11,57	43,14	0,27	0,789
D46	-102,96	43,14	-2,39	0,017
D47	-193,93	43,15	-4,49	0,000
D48	-277,67	43,15	-6,44	0,000
H1	4189,54	20,66	202,75	0,000
H2	4446,55	21,01	211,59	0,000
H3	4523,62	21,46	210,78	0,000
H4	4544,23	21,77	208,78	0,000
H5	4533,18	22,09	205,23	0,000
H6	4262,17	23,12	184,38	0,000
H7	3819,89	23,88	159,94	0,000
S35	-85,5	124,9	-0,68	0,493
S37	-94,9	124,9	-0,76	0,447
S38	-80,3	124,9	-0,64	0,520
S39	-112,1	124,9	-0,90	0,369
S40	-130,9	124,9	-1,05	0,295
S41	-103,3	124,9	-0,83	0,408
M35	-69,5	125,0	-0,56	0,578
M36	60,0	123,5	0,49	0,627
M37	55,6	125,0	0,45	0,656
M38	72,8	125,0	0,58	0,560
M39	84,0	125,0	0,67	0,502
M40	61,7	125,0	0,49	0,621
M41	90,4	125,0	0,72	0,470
M42	141,2	123,5	1,14	0,253
M43	157,4	123,5	1,27	0,203

Lampiran 45. Output Time Series Regression Window 5 dengan 59 Variabel Preditor (Lanjutan).

S = 227,038

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	59	26119727797	442707251	8588,58	0,000
Residual Error	1381	71185103	51546		
Total	1440	26190912901			

Lampiran 46. Output Time Series Regression Window 6 dengan 59 Variabel Preditor.

Y(t) = - 0,0126 t - 341 D1 - 391 D2 - 421 D3 - 465 D4 - 495 D5 - 523 D6 - 528 D7 - 474 D8 - 357 D9 - 246 D10 - 304 D11 - 456 D12 - 604 D13 - 613 D14 - 465 D15 - 317 D16 - 124 D24 - 114 D25 + 145 D27 + 128 D28 + 110 D29 + 117 D34 + 528 D35 + 652 D36 + 646 D37 + 604 D38 + 601 D39 + 555 D40 + 479 D41 + 335 D42 + 173 D43 + 60,4 D44 + 7,6 D45 - 106 D46 - 198 D47 - 280 D48 + 4101 H1 + 4417 H2 + 4495 H3 + 4517 H4 + 4505 H5 + 4231 H6 + 3787 H7 - 83 S35 - 88 S37 - 73 S38 - 106 S39 - 125 S40 - 98 S41 - 67 M35 + 65 M36 + 63 M37 + 81 M38 + 91 M39 + 68 M40 + 96 M41 + 147 M42 + 164 M43

Predictor	Coef	SE Coef	T	P
Noconstant				
t	-0,01260	0,01411	-0,89	0,372
D1	-341,20	41,86	-8,15	0,000
D2	-390,65	41,86	-9,33	0,000
D3	-421,38	41,86	-10,07	0,000
D4	-464,76	41,86	-11,10	0,000
D5	-494,96	41,86	-11,82	0,000
D6	-522,80	41,86	-12,49	0,000
D7	-528,07	41,86	-12,61	0,000
D8	-473,80	41,86	-11,32	0,000
D9	-356,80	41,86	-8,52	0,000
D10	-245,62	41,86	-5,87	0,000
D11	-304,20	41,86	-7,27	0,000
D12	-455,97	41,86	-10,89	0,000
D13	-604,19	41,86	-14,43	0,000
D14	-612,60	41,86	-14,63	0,000
D15	-465,24	41,86	-11,11	0,000
D16	-317,00	41,86	-7,57	0,000

**Lampiran 46. Output Time Series Regression Window 6 dengan
59 Variabel Preditor (Lanjutan).**

D24	-124,01	41,86	-2,96	0,003
D25	-113,81	41,86	-2,72	0,007
D27	145,04	41,86	3,46	0,001
D28	128,24	41,86	3,06	0,002
D29	110,17	41,86	2,63	0,009
D34	117,20	41,86	2,80	0,005
D35	527,76	48,53	10,87	0,000
D36	651,66	44,81	14,54	0,000
D37	645,80	48,53	13,31	0,000
D38	604,27	48,53	12,45	0,000
D39	600,88	48,53	12,38	0,000
D40	555,33	48,53	11,44	0,000
D41	478,52	48,53	9,86	0,000
D42	335,45	44,81	7,49	0,000
D43	172,96	44,81	3,86	0,000
D44	60,40	41,86	1,44	0,149
D45	7,64	41,86	0,18	0,855
D46	-105,89	41,86	-2,53	0,012
D47	-197,63	41,86	-4,72	0,000
D48	-280,13	41,86	-6,69	0,000
H1	4101,32	22,11	185,53	0,000
H2	4417,00	20,05	220,30	0,000
H3	4494,77	20,39	220,44	0,000
H4	4517,38	20,82	216,93	0,000
H5	4504,53	21,12	213,29	0,000
H6	4231,00	22,11	191,36	0,000
H7	3786,51	22,84	165,75	0,000
S35	-83,2	121,2	-0,69	0,493
S37	-88,3	121,2	-0,73	0,466
S38	-72,5	121,2	-0,60	0,549
S39	-105,7	121,2	-0,87	0,383
S40	-125,0	121,2	-1,03	0,302
S41	-97,9	121,2	-0,81	0,419
M35	-66,7	121,3	-0,55	0,583
M36	65,4	119,8	0,55	0,585
M37	62,7	121,3	0,52	0,605
M38	80,9	121,3	0,67	0,505
M39	90,9	121,3	0,75	0,454
M40	68,0	121,3	0,56	0,575
M41	96,2	121,3	0,79	0,428
M42	146,7	119,8	1,22	0,221
M43	163,9	119,8	1,37	0,172

Lampiran 46. Output Time Series Regression Window 6 dengan 59 Variabel Preditor (Lanjutan).

S = 220,294

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	59	26143782687	443114961	9130,88	0,000
Residual Error	1381	67018904	48529		
Total	1440	26210801592			

Lampiran 47. Output Time Series Regression Window 7 dengan 59 Variabel Preditor.

The regression equation is

Y(t) = - 0,0024 t - 342 D1 - 393 D2 - 422 D3 - 464 D4 - 495 D5 - 524 D6 - 529 D7 - 472 D8 - 356 D9 - 245 D10 - 308 D11 - 460 D12 - 607 D13 - 614 D14 - 465 D15 - 317 D16 - 121 D24 - 113 D25 + 144 D27 + 127 D28 + 110 D29 + 119 D34 + 533 D35 + 651 D36 + 646 D37 + 604 D38 + 600 D39 + 555 D40 + 479 D41 + 335 D42 + 173 D43 + 61,9 D44 + 9,1 D45 - 105 D46 - 197 D47 - 279 D48 + 4093 H1 + 4390 H2 + 4487 H3 + 4507 H4 + 4498 H5 + 4224 H6 + 3779 H7 - 88 S35 - 89 S37 - 73 S38 - 105 S39 - 125 S40 - 99 S41 - 72 M35 + 66 M36 + 62 M37 + 81 M38 + 92 M39 + 68 M40 + 95 M41 + 147 M42 + 164 M43

Predictor	Coef	SE Coef	T	P
Noconstant				
t	-0,00238	0,01408	-0,17	0,866
D1	-342,36	41,78	-8,19	0,000
D2	-392,95	41,78	-9,41	0,000
D3	-421,80	41,78	-10,10	0,000
D4	-464,25	41,78	-11,11	0,000
D5	-494,93	41,78	-11,85	0,000
D6	-523,83	41,78	-12,54	0,000
D7	-528,51	41,78	-12,65	0,000
D8	-472,31	41,78	-11,31	0,000
D9	-355,75	41,78	-8,52	0,000
D10	-245,14	41,78	-5,87	0,000
D11	-307,71	41,78	-7,37	0,000
D12	-459,53	41,78	-11,00	0,000
D13	-606,67	41,78	-14,52	0,000
D14	-614,07	41,78	-14,70	0,000
D15	-465,03	41,78	-11,13	0,000
D16	-317,04	41,78	-7,59	0,000

**Lampiran 47. Output Time Series Regression Window 7 dengan
59 Variabel Preditor (Lanjutan).**

D24	-121,25	41,78	-2,90	0,004
D25	-112,61	41,78	-2,70	0,007
D27	144,47	41,78	3,46	0,001
D28	127,19	41,78	3,04	0,002
D29	109,98	41,78	2,63	0,009
D34	118,79	41,78	2,84	0,005
D35	532,66	48,43	11,00	0,000
D36	651,08	44,72	14,56	0,000
D37	646,22	48,43	13,34	0,000
D38	604,05	48,43	12,47	0,000
D39	599,78	48,43	12,38	0,000
D40	555,30	48,43	11,47	0,000
D41	479,17	48,43	9,89	0,000
D42	335,39	44,72	7,50	0,000
D43	172,90	44,72	3,87	0,000
D44	61,85	41,78	1,48	0,139
D45	9,13	41,78	0,22	0,827
D46	-104,74	41,78	-2,51	0,012
D47	-197,17	41,78	-4,72	0,000
D48	-278,82	41,78	-6,67	0,000
H1	4092,84	21,72	188,46	0,000
H2	4390,34	22,06	199,01	0,000
H3	4487,02	20,01	224,25	0,000
H4	4506,91	20,35	221,48	0,000
H5	4497,52	20,78	216,42	0,000
H6	4223,63	21,76	194,07	0,000
H7	3778,65	22,49	168,05	0,000
S35	-88,3	120,9	-0,73	0,465
S37	-89,0	120,9	-0,74	0,462
S38	-72,6	120,9	-0,60	0,548
S39	-104,8	120,9	-0,87	0,386
S40	-125,3	120,9	-1,04	0,300
S41	-98,9	120,9	-0,82	0,414
M35	-71,8	121,0	-0,59	0,553
M36	65,8	119,6	0,55	0,582
M37	62,0	121,0	0,51	0,608
M38	80,9	121,0	0,67	0,504
M39	91,7	121,0	0,76	0,449
M40	67,8	121,0	0,56	0,576
M41	95,3	121,0	0,79	0,431
M42	146,5	119,6	1,23	0,221
M43	163,7	119,6	1,37	0,171

Lampiran 47. *Output Time Series Regression Window 7 dengan 59 Variabel Preditor (Lanjutan).*


S = 219,846

Analysis of Variance


Source	DF	SS	MS	F	P
Regression	59	26144682136	443130206	9168,41	0,000
Residual Error	1381	66746866	48332		
Total	1440	26211429002			

Lampiran 48. Normality Test dan ACF Residual Window 1-7
Model *Time Series Regression* dengan 59 Variabel Preditor.


a. Window 1




b. Window 2




c. Window 3




d. Window 4




e. Window 5



f. *Window 6*



g. *Window 7*



Lampiran 49. *Output Random Forest Window 1 Model Double Seasonal ARIMA.*

```
> e=read.csv("D:/nay/RF_ARIMA_window time/model 1.csv",header=T,sep=",")
> ve <- VSURF(Yt ~ ., data = e, ntree=1000, nfor.thres=40, nfor.interp=20,
> summary(ve)
VSURF computation time: 11.7 hours

VSURF selected:
      136 variables at thresholding step (in 1.7 hours)
      105 variables at interpretation step (in 8 hours)
      26 variables at prediction step (in 2 hours)
> plot(ve, step = "thres", imp.sd = FALSE, var.names = TRUE)
> number <- c(1:385)
> number[ve$vselect.thres]
 [1] 1  2 336  3 48 335 337  4 47 384 288  5 334 49  6 383 287 18 11  7
 9  8 17 333
[25] 10 286 338 16 37 15 382 240 46 14 12 19 13 192 29 239 144 385 289
332 285 191 351 28
[49] 281 30 350 280 22 321 320 282 50 147 36 57 20 331 381 325 354 27
25 26 347 284 352 96
[73] 283 349 21 299 348 339 330 238 322 58 23 329 24 143 313 99 328 310
31 345 195 279 40 39
[97] 324 33 45 346 32 306 380 146 359 56 353 194 277 38 358 190 318 98
34 188 361 317 327 355
[121] 342 60 59 343 312 362 344 360 63 173 341 314 189 340 326 95
> number[ve$vselect.interp]
 [1] 1  2 336  3 48 335 337  4 47 384 288  5 334 49  6 383 287 18 11  7
 9  8 17 333
[25] 10 286 338 16 37 15 382 240 46 14 12 19 13 192 29 239 144 385 289
332 285 191 351 28
[49] 281 30 350 280 22 321 320 282 50 147 36 57 20 331 381 325 354 27
25 26 347 284 352 96
[73] 283 349 21 299 348 339 330 238 322 58 23 329 24 143 313 99 328 310
31 345 195 279 40 39
[97] 324 33 45 346 32 306 380 146 359
> number[ve$vselect.pred]
 [1] 1  2 336  3 48 335 337 288  5 383 18 11 338 192 29 239 147 36 57
349 21 299 348 339
[25] 146 359
```

Lampiran 50. *Output Random Forest Window 2 Model Double Seasonal ARIMA.*

```
> e=read.csv("D:/nay/RF_ARIMA_window time/model 2.csv",header=T,sep=",")
> ve <- VSURF(Yt ~ ., data = e, ntree=1000, nfor.thres=40, nfor.interp=20,
nfor.pred=20, nmin=10)
> summary(ve)
VSURF computation time: 8.1 hours

VSURF selected:
      102 variables at thresholding step (in 1.7 hours)
      90 variables at interpretation step (in 4.6 hours)
      30 variables at prediction step (in 1.8 hours)
> plot(ve, step = "thres", imp.sd = FALSE, var.names = TRUE)
> number <- c(1:385)
> number[ve$varselect.thres]
 [1]  1  2 336  3 335 48 337  4 47 384 288  5 334 383  6 49 287 11 18  9
 7  8 333 17
[25] 10 286 382 338 37 16 12 15 14 19 240 46 192 13 239 385 332 144
289 29 351 285 350 281
[49] 57 191 36 280 282 22 381 30 28 20 147 321 284 354 40 50 58 349
320 25 352 345 283 347
[73] 348 331 56 143 238 26 299 27 325 310 24 39 328 359 96 195 339 23
358 21 353 146 99 279
[97] 38 194 346 313 31 360
> number[ve$varselect.interp]
 [1]  1  2 336  3 335 48 337  4 47 384 288  5 334 383  6 49 287 11 18  9  7
 8 333 17
[25] 10 286 382 338 37 16 12 15 14 19 240 46 192 13 239 385 332 144 289
29 351 285 350 281
[49] 57 191 36 280 282 22 381 30 28 20 147 321 284 354 40 50 58 349 320
25 352 345 283 347
[73] 348 331 56 143 238 26 299 27 325 310 24 39 328 359 96 195 339 23
> number[ve$varselect.pred]
 [1]  1  2 336  3 335 48 337 288  5 383 11 18 382 338 37 192 29 351 285
191 36 22 147 321
[25] 349 25 352 56 195 339
```

Lampiran 51. *Output Random Forest Window 3 Model Double Seasonal ARIMA.*

```

> e=read.csv("D:/nay/RF_ARIMA_window time/model 3.csv",header=T,sep=",")
> ve <- VSURF(Yt ~ ., data = e, ntree=1000, nfor.thres=40, nfor.interp=20,
nfor.pred=20, nmin=10)
> summary(ve)
VSURF computation time: 12.9 hours
VSURF selected:
      145 variables at thresholding step (in 1.7 hours)
      97 variables at interpretation step (in 9.3 hours)
      25 variables at prediction step (in 2 hours)
> plot(ve, step = "thres", imp.sd = FALSE, var.names = TRUE)
There were 50 or more warnings (use warnings() to see the first 50)
> number <- c(1:385)
There were 50 or more warnings (use warnings() to see the first 50)
> number[ve$varselect.thres]
 [1] 1  2 336  3 335 48 337  4 47 384  5 383 288 334  6 49 11 287 18  9
 7  8 333 17 286 382 10 338 37 15 16 12 19 46 14 285 240 13 332 192 29
385 144 351 239 350 57 284 280 289 381 22 36 321 281 282 191 147 30 320
20 28 40 352 50 283 310 354 349 25 26 345
[73] 348 279 347 58 39 313 38 331 23 27 339 325 299 328 238 143 99 56
195 63 361 24 21 322
[97] 359 59 33 31 96 353 358 146 344 380 45 190 302 318 34 346 360 362
324 317 41 32 188 194
[121] 329 343 306 312 98 60 327 62 342 341 82 316 373 326 314 35 370 340
64 307 319 330 52 189
[145] 355
> number[ve$varselect.interp]
 [1] 1  2 336  3 335 48 337  4 47 384  5 383 288 334  6 49 11 287 18  9  7
 8 333 17 286 382 10 338 37 15 16 12 19 46 14 285 240 13 332 192 29
385 144 351 239 350 57 284
[49] 280 289 381 22 36 321 281 282 191 147 30 320 20 28 40 352 50 283
310 354 349 25 26 345
[73] 348 279 347 58 39 313 38 331 23 27 339 325 299 328 238 143 99 56
195 63 361 24 21 322
[97] 359
> number[ve$varselect.pred]
 [1] 1  2 336  3 335 48 337 288 334 11 18  9 286 382 10 338 192 29 351
191 147 348 339 325
[25] 195

```


Lampiran 52. *Output Random Forest Window 4 Model Double Seasonal ARIMA.*

```
> e=read.csv("D:/nay/RF_ARIMA_window time/model 4.csv",header=T,sep=",")
> ve <- VSURF(Yt ~ ., data = e, ntree=1000, nfor.thres=40, nfor.interp=20,
nfor.pred=20, nmin=10)
> summary(ve)
VSURF computation time: 11.2 hours
VSURF selected:
      129 variables at thresholding step (in 1.8 hours)
      92 variables at interpretation step (in 7.5 hours)
      27 variables at prediction step (in 2 hours)
> plot(ve, step = "thres", imp.sd = FALSE, var.names = TRUE)
> number <- c(1:385)
> number[ve$varselect.thres]
 [1]  1  2 336  3 335 48 337  4 47  5 384 334 383  6 288  9 11 287 49 18
 7 333  8 17 286 338 10 382 37 19 240 332 16 12 285 46 15 192 239 280
14 29 351 13 284 144 281 350
[49] 385 57 282 40 36 321 147 20 191 22 320 283 238 325 39 28 352 30
289 279 331 195 349 328
[73] 310 324 354 25 26 381 313 348 58 38 345 50 143 27 339 41 99 347
299 56 23 21 33 24
[97] 194 32 353 318 31 322 317 361 344 96 34 327 329 45 316 59 358 359
188 326 190 346 146 314
[121] 319 330 63 302 312 60 360 362 380
> number[ve$varselect.interp]
 [1]  1  2 336  3 335 48 337  4 47  5 384 334 383  6 288  9 11 287 49 18  7
333  8 17
[25] 286 338 10 382 37 19 240 332 16 12 285 46 15 192 239 280 14 29 351
13 284 144 281 350
[49] 385 57 282 40 36 321 147 20 191 22 320 283 238 325 39 28 352 30
289 279 331 195 349 328
[73] 310 324 354 25 26 381 313 348 58 38 345 50 143 27 339 41 99 347
299 56
> number[ve$varselect.pred]
 [1]  1  2 336  3 335 48 337 288  9 11 286 338 382 19 240 29 351 13 350
147 20 191 22 320
[25] 195 25 381
```

Lampiran 53. *Output Random Forest Window 5 Model Double Seasonal ARIMA.*

```
> e=read.csv("D:/nay/RF_ARIMA_window time/model 5.csv",header=T,sep=",")
> ve <- VSURF(Yt ~ ., data = e, ntree=1000, nfor.thres=40, nfor.interp=20,
nfor.pred=20, nmin=10)
> summary(ve)
VSURF computation time: 10.7 hours

VSURF selected:
      129 variables at thresholding step (in 1.7 hours)
      81 variables at interpretation step (in 7.3 hours)
      30 variables at prediction step (in 1.7 hours)
> plot(ve, step = "thres", imp.sd = FALSE, var.names = TRUE)
> number <- c(1:385)
> number[ve$varselect.thres]
 [1]  1  2 336  3 335 48  4 337 47  5 384 288 334  6 383 287 11  9 49  7
18  8 333 17
[25] 286 10 338 382 37 19 16 240 12 332 285 239 15 46 14 280 192 29
147 13 281 20 144 351
[49] 284 385 36 350 282 57 289 321 191 320 283 28 279 22 238 195 40 354
331 39 325 381 30 352
[73] 310 345 56 38 324 194 25 26 349 27 353 299 50 146 348 313 339 21
328 143 23 347 329 99
[97] 190 45 96 316 24 188 327 330 58 344 312 322 34 33 346 318 317 311
302 41 189 32 148 31
[121] 380 326 59 355 359 319 361 358 342
> number[ve$varselect.interp]
 [1]  1  2 336  3 335 48  4 337 47  5 384 288 334  6 383 287 11  9 49  7 18
 8 333 17
[25] 286 10 338 382 37 19 16 240 12 332 285 239 15 46 14 280 192 29 147
13 281 20 144 351
[49] 284 385 36 350 282 57 289 321 191 320 283 28 279 22 238 195 40 354
331 39 325 381 30 352
[73] 310 345 56 38 324 194 25 26 349
> number[ve$varselect.pred]
 [1]  1  2 336  3 335 48 337 288 334 383 11  9  7 338 382 37 239 15 29 147
13 144 351 284
[25] 350 191 320 194 25 26
```

Lampiran 54. *Output Random Forest Window 6 Model Double Seasonal ARIMA.*

```

> e=read.csv("D:/nay/RF_ARIMA_window time/model 6.csv",header=T,sep=",")
> ve <- VSURF(Yt ~ ., data = e, ntree=1000, nfor.thres=40, nfor.interp=20,
nfor.pred=20, nmin=10)
> summary(ve)
VSURF computation time: 12.1 hours

VSURF selected:
      141 variables at thresholding step (in 1.8 hours)
       81 variables at interpretation step (in 8.8 hours)
       22 variables at prediction step (in 1.5 hours)
> plot(ve, step = "thres", imp.sd = FALSE, var.names = TRUE)
> number <- c(1:385)
> number[ve$varselect.thres]
 [1]  1  2 336  3 48 335  4 337 47 384  5 383 49 288 334  6 287 11  9  7
333  8 18 286
[25] 382 17 10 37 240 239 46 12 19 192 332 285 385 238 16 29 338 280
15 281 282 14 36 147
[49] 325 284 381 351 57 40 191 289 20 50 321 324 283 350 320 13 144 39
279 22 28 26 331 354
[73] 30 195 38 45 345 41 25 27 313 352 56 299 310 146 353 349 344 194
328 42 99 322 44 314
[97] 316 318 237 21 319 58 347 23 190 348 34 327 96 32 43 339 317 188
24 143 33 380 359 31
[121] 330 326 173 329 59 346 358 315 361 302 189 373 312 360 35 342 228
370 166 181 174
> number[ve$varselect.interp]
 [1]  1  2 336  3 48 335  4 337 47 384  5 383 49 288 334  6 287 11  9  7
333  8 18 286
[25] 382 17 10 37 240 239 46 12 19 192 332 285 385 238 16 29 338 280 15
281 282 14 36 147
[49] 325 284 381 351 57 40 191 289 20 50 321 324 283 350 320 13 144 39
279 22 28 26 331 354
[73] 30 195 38 45 345 41 25 27 313
> number[ve$varselect.pred]
 [1]  1  2 336  3 48 335 337 288 334 11 18 286 382 37 240 239 29 338 147
351 57 321

```


Lampiran 55. *Output Random Forest Window 7 Model Double Seasonal ARIMA.*

```
> e=read.csv("D:/nay/RF_ARIMA_window time/model 7.csv",header=T,sep=",")
> ve <- VSURF(Yt ~ ., data = e, ntree=1000, nfor.thres=40, nfor.interp=20,
nfor.pred=20, nmin=10)
> summary(ve)
VSURF computation time: 8.5 hours


VSURF selected:
      108 variables at thresholding step (in 1.7 hours)
      93 variables at interpretation step (in 5.1 hours)
      25 variables at prediction step (in 1.8 hours)
> plot(ve, step = "thres", imp.sd = FALSE, var.names = TRUE)
> number <- c(1:385)
> number[ve$varselect.thres]
 [1]  1  2 336  3 48 335  4 337 47 384  5 383 49 288 334  6 287 11  9  7
333  8 18 382
[25] 286 17 10 240 37 239 385 12 19 332 46 192 238 285 16 280 15 338
14 29 281 147 282 325
[49] 381 284 289 36 321 57 191 20 351 350 40 13 50 283 144 354 324 320
279 28 39 26 331 195
[73] 22 30 345 25 352 45 27 328 310 56 38 313 96 349 299 146 353 237
41 194 58 348 318 190
[97] 316 344 347 322 380 317 42 99 327 314 143 21
> number[ve$varselect.interp]
 [1]  1  2 336  3 48 335  4 337 47 384  5 383 49 288 334  6 287 11  9  7
333  8 18 382
[25] 286 17 10 240 37 239 385 12 19 332 46 192 238 285 16 280 15 338 14
29 281 147 282 325
[49] 381 284 289 36 321 57 191 20 351 350 40 13 50 283 144 354 324 320
279 28 39 26 331 195
[73] 22 30 345 25 352 45 27 328 310 56 38 313 96 349 299 146 353 237 41
194 58
> number[ve$varselect.pred]
 [1]  1  2 336  3 48 335 337 288 334 11 382 286 17 239 385 19 338 14 29
147 282 381 351 350
[25] 324
```

Lampiran 56. *Output Plot Ranking Variabel dengan Random Forest pada Model Double Seasonal ARIMA Window 1-7.*


a. *Window 1*




b. *Window 2*




c. Window 3




d. Window 4




e. Window 5



f. *Window 6*



g. *Window 7*



Lampiran 57. *Syntax Double Seasonal ARIMA pada Window 1 dengan Seleksi Input Random Forest.*

```

data listrik;
input y;
datalines;
3988.1
3945.2
3959.5
3909.4
3800.0
:
4091.0
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate
  p=(1, 2, 3, 5, 11, 18, 21, 29, 36, 48, 57, 146, 147, 192,
    239, 288, 299, 335, 336, 337, 338, 339, 348, 349, 359,
    383) (0) (0) q=(1) (48) (336) noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanDSARIMAmodel1.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```


Lampiran 58. *Output Double Seasonal ARIMA pada Window 1 dengan Seleksi Input Random Forest.*

The ARIMA Procedure					
Maximum Likelihood Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.35758	0.12538	2.85	0.0043	1
MA2,1	0.95856	0.09590	10.00	<.0001	48
MA3,1	0.99999	6028.5	0.00	0.9999	336
AR1,1	0.25412	0.12480	2.04	0.0417	1
AR1,2	0.06408	0.02756	2.33	0.0201	2
AR1,3	0.0095642	0.02462	0.39	0.6977	3
AR1,4	0.05788	0.02280	2.54	0.0111	5
AR1,5	0.05967	0.02236	2.67	0.0076	11
AR1,6	-0.04384	0.02228	-1.97	0.0491	18
AR1,7	-0.05785	0.02287	-2.53	0.0114	21
AR1,8	0.01229	0.02215	0.56	0.5788	29
AR1,9	0.02346	0.02231	1.05	0.2931	36
AR1,10	0.04481	0.02905	1.54	0.1229	48
AR1,11	0.03869	0.02231	1.73	0.0828	57
AR1,12	0.02038	0.02414	0.84	0.3985	146
AR1,13	-0.04527	0.02378	-1.90	0.0570	147
AR1,14	-0.03354	0.02391	-1.40	0.1607	192
AR1,15	-0.03088	0.02383	-1.30	0.1950	239
AR1,16	0.02382	0.02537	0.94	0.3478	288
AR1,17	0.03851	0.02444	1.58	0.1152	299
AR1,18	-0.03894	0.03054	-1.28	0.2022	335
AR1,19	0.0082311	0.07028	0.12	0.9068	336
AR1,20	-0.05154	0.03624	-1.42	0.1549	337
AR1,21	0.02642	0.03142	0.84	0.4003	338
AR1,22	-0.03681	0.02873	-1.28	0.2001	339
AR1,23	0.02396	0.02813	0.85	0.3944	348
AR1,24	0.0008614	0.02774	0.03	0.9752	349
AR1,25	-0.0010585	0.02560	-0.04	0.9670	359
AR1,26	-0.03662	0.02647	-1.38	0.1665	383
Variance Estimate			1379.402		
Std Error Estimate			37.1403		
AIC			11280.82		
SBC			11424.7		
Number of Residuals			1055		

Lampiran 58. *Output Double Seasonal ARIMA pada Window 1 dengan Seleksi Input Random Forest (Lanjutan).*

Autocorrelation Check of Residuals									
To	Chi-	Pr >	-----Autocorrelations-----						
Lag	Square	DF	ChiSq						
6	.	0	.	-0.002	0.010	0.002	0.001	-0.002	0.065
12	.	0	.	-0.047	0.042	0.037	0.022	0.017	-0.034
18	.	0	.	-0.024	0.064	-0.043	-0.012	-0.029	0.020
24	.	0	.	-0.032	-0.088	-0.005	-0.027	-0.055	0.055
30	46.89	1	<.0001	0.012	0.056	0.025	0.002	-0.010	0.068
36	53.70	7	<.0001	-0.038	0.013	-0.005	-0.025	0.058	0.024
42	67.41	13	<.0001	-0.046	-0.026	-0.049	0.015	0.011	-0.083
48	74.55	19	<.0001	0.008	-0.026	-0.041	-0.062	0.009	0.008

Lampiran 59. *Syntax Double Seasonal ARIMA pada Window 2 dengan Seleksi Input Random Forest.*

```

data listrik;
input y;
datalines;
4042.9
3980.0
3931.1
:
3720.5
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate p=(1, 2, 3, 5, 11, 18, 22, 25, 29, 36, 37, 48, 56,
147, 191, 192, 195, 285, 288, 321, 335, 336, 337, 338, 339,
349, 351, 352, 382, 383) (0) (0) q=(1) (48) (336)
  noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanDSARIMAmodel2.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```

Lampiran 60. *Output Double Seasonal ARIMA pada Window 2 dengan Seleksi Input Random Forest.*

Maximum Likelihood Estimation					
Parameter	Standard		Approx		Lag
	Estimate	Error	t Value	Pr > t	
MA1,1	0.13474	0.14519	0.93	0.3534	1
MA2,1	0.88621	0.04336	20.44	<.0001	48
MA3,1	0.99974	164.69314	0.01	0.9952	336
AR1,1	0.06538	0.14415	0.45	0.6501	1
AR1,2	0.05314	0.02802	1.90	0.0579	2
AR1,3	0.02032	0.02693	0.75	0.4506	3
AR1,4	0.04610	0.02492	1.85	0.0644	5
AR1,5	0.06765	0.02507	2.70	0.0070	11
AR1,6	-0.04419	0.02494	-1.77	0.0765	18
AR1,7	-0.06325	0.02505	-2.52	0.0116	22
AR1,8	0.01070	0.02516	0.43	0.6707	25
AR1,9	0.01611	0.02497	0.64	0.5190	29
AR1,10	0.05539	0.02537	2.18	0.0290	36
AR1,11	-0.05608	0.02608	-2.15	0.0315	37
AR1,12	0.07024	0.03537	1.99	0.0470	48
AR1,13	0.02206	0.02512	0.88	0.3799	56
AR1,14	-0.02717	0.02579	-1.05	0.2921	147
AR1,15	-0.02078	0.02642	-0.79	0.4315	191
AR1,16	-0.04686	0.02756	-1.70	0.0890	192
AR1,17	-0.03057	0.02644	-1.16	0.2476	195
AR1,18	0.0081179	0.02764	0.29	0.7690	285
AR1,19	0.02646	0.02944	0.90	0.3688	288
AR1,20	0.04668	0.02811	1.66	0.0968	321
AR1,21	0.0025086	0.03104	0.08	0.9356	335
AR1,22	0.08452	0.07232	1.17	0.2426	336
AR1,23	0.0055454	0.03259	0.17	0.8649	337
AR1,24	-0.02356	0.02949	-0.80	0.4243	338
AR1,25	-0.01787	0.02956	-0.60	0.5454	339
AR1,26	0.01319	0.02784	0.47	0.6357	349
AR1,27	-0.0058025	0.02819	-0.21	0.8369	351
AR1,28	0.01690	0.02789	0.61	0.5445	352
AR1,29	0.07127	0.02995	2.38	0.0173	382
AR1,30	-0.06644	0.03133	-2.12	0.0339	383
Variance Estimate		1503.384			
Std Error Estimate		38.77349			
AIC		11278.18			
SBC		11441.9			
Number of Residuals		1055			

Lampiran 60. *Output Double Seasonal ARIMA pada Window 2 dengan Seleksi Input Random Forest (Lanjutan).*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	0.003	0.017	-0.004	0.028	-0.009	0.083
12	.	0	.	-0.049	0.042	0.023	0.042	0.007	-0.037
18	.	0	.	-0.022	0.070	-0.024	-0.001	-0.030	0.003
24	.	0	.	-0.036	-0.069	-0.059	-0.010	-0.046	0.042
30	.	0	.	0.003	0.052	0.006	0.010	0.004	0.058
36	47.63	3	<.0001	-0.027	0.014	0.002	-0.021	0.018	0.006
42	57.90	9	<.0001	-0.003	-0.021	-0.035	-0.007	0.025	-0.084
48	62.42	15	<.0001	-0.002	-0.035	-0.030	-0.038	0.011	-0.020

Lampiran 61. *Syntax Double Seasonal ARIMA pada Window 3 dengan Seleksi Input Random Forest.*

```

data listrik;
input y;
datalines;
4013.4
4023.0
3930.0
:
3580.9
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate p=(1, 2, 3, 9, 10, 11, 18, 29, 48, 147, 191, 192,
195, 286, 288, 325, 334, 335, 336, 337, 338, 339, 348, 351,
382) (0) (0) q=(1) (48) (336) noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanDSARIMAmodel3.xls"
  dbms=excel97
  replace;
  sheet="1";
run;

```

Lampiran 62. *Output Double Seasonal ARIMA pada Window 3 dengan Seleksi Input Random Forest.*

Maximum Likelihood Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.09266	0.18562	0.50	0.6176	1
MA2,1	0.76116	0.03518	21.64	<.0001	48
MA3,1	0.99951	88.67743	0.01	0.9910	336
AR1,1	0.02926	0.18455	0.16	0.8740	1
AR1,2	0.03273	0.03019	1.08	0.2783	2
AR1,3	0.01453	0.02633	0.55	0.5811	3
AR1,4	0.03603	0.02427	1.48	0.1376	9
AR1,5	0.01312	0.02470	0.53	0.5951	10
AR1,6	0.05375	0.02498	2.15	0.0314	11
AR1,7	-0.04557	0.02415	-1.89	0.0592	18
AR1,8	0.02064	0.02392	0.86	0.3881	29
AR1,9	0.01415	0.03701	0.38	0.7022	48
AR1,10	-0.01991	0.02526	-0.79	0.4306	147
AR1,11	-0.01431	0.02507	-0.57	0.5681	191
AR1,12	-0.04384	0.02618	-1.67	0.0940	192
AR1,13	-0.03609	0.02577	-1.40	0.1614	195
AR1,14	-0.02968	0.02683	-1.11	0.2687	286
AR1,15	0.07441	0.02699	2.76	0.0058	288
AR1,16	-0.0027536	0.02765	-0.10	0.9207	325
AR1,17	-0.06963	0.02946	-2.36	0.0181	334
AR1,18	-0.0046628	0.03250	-0.14	0.8859	335
AR1,19	-0.01081	0.06599	-0.16	0.8698	336
AR1,20	-0.02428	0.02932	-0.83	0.4077	337
AR1,21	-0.03908	0.03091	-1.26	0.2061	338
AR1,22	-0.01229	0.03023	-0.41	0.6842	339
AR1,23	0.02827	0.02784	1.02	0.3098	348
AR1,24	-0.02746	0.02731	-1.01	0.3146	351
AR1,25	0.02041	0.02774	0.74	0.4618	382
Variance Estimate			1488.349		
Std Error Estimate			38.57913		
AIC			11265.96		
SBC			11404.88		
Number of Residuals			1055		

Lampiran 62. *Output Double Seasonal ARIMA pada Window 3 dengan Seleksi Input Random Forest (Lanjutan).*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	0.005	-0.002	-0.004	0.008	0.033	0.100
12	.	0	.	-0.058	0.037	0.005	0.016	0.006	-0.037
18	.	0	.	-0.024	0.061	-0.043	-0.021	-0.024	0.011
24	.	0	.	-0.036	-0.066	-0.053	-0.053	-0.044	0.035
30	51.30	2	<.0001	-0.010	0.053	0.015	0.002	0.001	0.074
36	54.27	8	<.0001	-0.021	0.011	-0.012	-0.018	0.030	0.029
42	64.43	14	<.0001	-0.031	-0.012	-0.048	0.003	0.028	-0.071
48	71.72	20	<.0001	-0.007	-0.017	-0.032	-0.057	0.038	-0.024

Lampiran 63. *Syntax Double Seasonal ARIMA pada Window 4 dengan Seleksi Input Random Forest.*

```

data listrik;
input y;
datalines;
3833.5
3783.4
3737.7
:
3938.2
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate p=(1, 2, 3, 9, 11, 13, 19, 20, 22, 25, 29, 48, 147,
191, 195, 240, 286, 288, 320, 335, 336, 337, 338, 350, 351,
381, 382) (0) (0) q=(1) (48) (336) noconstant
  method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanDSARIMAmodel4.xls"
  dbms=excel97
  replace;
  sheet="1";

```

Lampiran 64. *Output Double Seasonal ARIMA pada Window 4 dengan Seleksi Input Random Forest.*

Maximum Likelihood Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.37475	0.14372	2.61	0.0091	1
MA2,1	0.76429	0.03190	23.96	<.0001	48
MA3,1	0.99971	159.17010	0.01	0.9950	336
AR1,1	0.29971	0.14352	2.09	0.0368	1
AR1,2	0.06117	0.02952	2.07	0.0383	2
AR1,3	0.01991	0.02605	0.76	0.4448	3
AR1,4	0.04775	0.02360	2.02	0.0431	9
AR1,5	0.04523	0.02462	1.84	0.0662	11
AR1,6	-0.02522	0.02379	-1.06	0.2891	13
AR1,7	-0.03908	0.02487	-1.57	0.1160	19
AR1,8	-0.06697	0.02653	-2.52	0.0116	20
AR1,9	-0.05951	0.02608	-2.28	0.0225	22
AR1,10	0.02978	0.02376	1.25	0.2101	25
AR1,11	0.02318	0.02372	0.98	0.3284	29
AR1,12	0.0003839	0.03167	0.01	0.9903	48
AR1,13	-0.01089	0.02441	-0.45	0.6554	147
AR1,14	-0.01256	0.02458	-0.51	0.6093	191
AR1,15	-0.02975	0.02525	-1.18	0.2387	195
AR1,16	-0.02369	0.02437	-0.97	0.3310	240
AR1,17	-0.04534	0.02663	-1.70	0.0886	286
AR1,18	0.07027	0.02693	2.61	0.0091	288
AR1,19	0.01392	0.02543	0.55	0.5840	320
AR1,20	-0.0006287	0.02974	-0.02	0.9831	335
AR1,21	0.01442	0.06288	0.23	0.8187	336
AR1,22	-0.02196	0.03681	-0.60	0.5508	337
AR1,23	-0.01615	0.03039	-0.53	0.5950	338
AR1,24	-0.01601	0.02745	-0.58	0.5598	350
AR1,25	0.0009489	0.02773	0.03	0.9727	351
AR1,26	0.02334	0.02788	0.84	0.4025	381
AR1,27	-0.01325	0.02806	-0.47	0.6367	382
Variance Estimate		1479.887			
Std Error Estimate		38.4693			
AIC		11248.59			
SBC		11397.43			
Number of Residuals		1055			

Lampiran 64. *Output Double Seasonal ARIMA pada Window 4 dengan Seleksi Input Random Forest (Lanjutan).*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	Pr > DF	ChiSq	-----Autocorrelations-----					
6	.	0	.	0.002	0.029	-0.015	0.032	0.040	0.087
12	.	0	.	-0.042	0.021	-0.011	0.035	0.019	-0.057
18	.	0	.	-0.002	0.066	-0.021	-0.010	-0.030	-0.058
24	.	0	.	0.002	-0.006	-0.031	-0.006	-0.035	0.025
30	.	0	.	-0.016	0.048	0.014	0.027	-0.022	0.088
36	47.65	6	<.0001	-0.020	0.008	0.002	-0.020	0.016	0.031
42	60.91	12	<.0001	-0.035	-0.007	-0.054	-0.015	0.012	-0.086
48	74.31	18	<.0001	-0.030	-0.028	-0.026	-0.064	0.070	-0.028

Lampiran 65. *Syntax Double Seasonal ARIMA pada Window 5 dengan Seleksi Input Random Forest.*

```

data listrik;
input y;
datalines;
3737.6
3698.3
3667.4
:
4048.4
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate p=(1, 2, 3, 7, 9, 11, 13, 15, 25, 26, 29, 37, 48, 144,
147, 191, 194, 239, 284, 288, 320, 334, 335, 336, 337, 338,
350, 351, 382, 383) (0) (0) q=(1) (48) (336) noconstant
  method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanDSARIMAmode15.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```


Lampiran 66. *Output Double Seasonal ARIMA pada Window 5 dengan Seleksi Input Random Forest.*

Maximum Likelihood Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.33477	0.15106	2.22	0.0267	1
MA2,1	0.72172	0.03599	20.05	<.0001	48
MA3,1	0.99810	35.66005	0.03	0.9777	336
AR1,1	0.25768	0.15077	1.71	0.0874	1
AR1,2	0.08149	0.03307	2.46	0.0137	2
AR1,3	0.0056293	0.02799	0.20	0.8406	3
AR1,4	-0.03301	0.02458	-1.34	0.1793	7
AR1,5	0.06790	0.02486	2.73	0.0063	9
AR1,6	0.03766	0.02490	1.51	0.1304	11
AR1,7	0.0011589	0.02520	0.05	0.9633	13
AR1,8	-0.04355	0.02701	-1.61	0.1069	15
AR1,9	0.01380	0.02533	0.55	0.5857	25
AR1,10	0.03817	0.02607	1.46	0.1431	26
AR1,11	0.03945	0.02471	1.60	0.1103	29
AR1,12	-0.05615	0.02443	-2.30	0.0215	37
AR1,13	0.01242	0.03706	0.34	0.7375	48
AR1,14	-0.0048946	0.02730	-0.18	0.8577	144
AR1,15	-0.01840	0.02517	-0.73	0.4648	147
AR1,16	-0.02155	0.02591	-0.83	0.4055	191
AR1,17	-0.03118	0.02618	-1.19	0.2337	194
AR1,18	-0.0048130	0.02605	-0.18	0.8534	239
AR1,19	-0.02924	0.02589	-1.13	0.2587	284
AR1,20	0.08120	0.02775	2.93	0.0034	288
AR1,21	-0.01636	0.02706	-0.60	0.5453	320
AR1,22	-0.05457	0.02989	-1.83	0.0679	334
AR1,23	0.01545	0.03376	0.46	0.6473	335
AR1,24	0.03410	0.06730	0.51	0.6124	336
AR1,25	-0.02066	0.03617	-0.57	0.5680	337
AR1,26	-0.03008	0.03273	-0.92	0.3581	338
AR1,27	-0.0067957	0.02773	-0.25	0.8064	350
AR1,28	0.0057273	0.03053	0.19	0.8512	351
AR1,29	-0.0066025	0.02798	-0.24	0.8135	382
AR1,30	-0.0007890	0.02849	-0.03	0.9779	383
Variance Estimate			1543.543		
Std Error Estimate			39.28795		
AIC			11275.32		
SBC			11439.04		
Number of Residuals			1055		

Lampiran 66. *Output Double Seasonal ARIMA pada Window 5 dengan Seleksi Input Random Forest (Lanjutan).*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	0.028	-0.010	0.004	0.036	0.041	0.074
12	.	0	.	-0.000	0.016	-0.016	0.047	0.029	-0.068
18	.	0	.	-0.027	0.051	0.011	-0.015	-0.031	-0.058
24	.	0	.	-0.049	-0.084	-0.049	-0.072	-0.041	0.016
30	.	0	.	-0.013	0.012	-0.002	0.007	-0.017	0.074
36	57.42	3	<.0001	-0.011	0.015	0.007	-0.041	0.007	0.028
42	62.63	9	<.0001	0.018	0.002	-0.016	0.005	0.016	-0.062
48	75.82	15	<.0001	-0.017	-0.003	-0.036	-0.063	0.053	-0.059

Lampiran 67. *Syntax Double Seasonal ARIMA pada Window 6 dengan Seleksi Input Random Forest.*

```

data listrik;
input y;
datalines;
4032.5
4008.9
3970.8
:
4079.4
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate p=(1, 2, 3, 11, 18, 29, 37, 48, 57, 147, 239, 240, 286,
288, 321, 334, 335, 336, 337, 338, 351, 382) (0) (0) q=(1)
(48) (336) noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanDSARIMAmode16.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```

Lampiran 68. *Output Double Seasonal ARIMA pada Window 6 dengan Seleksi Input Random Forest.*

Maximum Likelihood Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.55811	0.12268	4.55	<.0001	1
MA2,1	0.76005	0.02975	25.55	<.0001	48
MA3,1	0.99842	52.16876	0.02	0.9847	336
AR1,1	0.46879	0.12243	3.83	0.0001	1
AR1,2	0.06211	0.03322	1.87	0.0615	2
AR1,3	0.03774	0.02640	1.43	0.1528	3
AR1,4	0.03261	0.02113	1.54	0.1228	11
AR1,5	-0.06973	0.02180	-3.20	0.0014	18
AR1,6	0.02769	0.02158	1.28	0.1994	29
AR1,7	-0.06006	0.02209	-2.72	0.0065	37
AR1,8	-0.03033	0.02805	-1.08	0.2797	48
AR1,9	-0.0079415	0.02185	-0.36	0.7163	57
AR1,10	-0.02202	0.02263	-0.97	0.3304	147
AR1,11	-0.02377	0.02805	-0.85	0.3967	239
AR1,12	0.02673	0.02845	0.94	0.3475	240
AR1,13	-0.0075710	0.02633	-0.29	0.7737	286
AR1,14	0.03598	0.02641	1.36	0.1731	288
AR1,15	0.01644	0.02298	0.72	0.4744	321
AR1,16	-0.05487	0.03014	-1.82	0.0687	334
AR1,17	0.02221	0.03505	0.63	0.5263	335
AR1,18	0.03512	0.07356	0.48	0.6331	336
AR1,19	-0.05371	0.04825	-1.11	0.2657	337
AR1,20	-0.0079631	0.03339	-0.24	0.8115	338
AR1,21	-0.0027130	0.02262	-0.12	0.9045	351
AR1,22	-0.01088	0.02301	-0.47	0.6362	382
Variance Estimate			1525.882		
Std Error Estimate			39.06254		
AIC			11267		
SBC			11391.04		
Number of Residuals			1055		

Lampiran 68. *Output Double Seasonal ARIMA pada Window 6 dengan Seleksi Input Random Forest (Lanjutan).*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.012	-0.011	-0.012	0.012	0.025	0.052
12	.	0	.	-0.051	-0.000	0.030	0.076	0.022	-0.048
18	.	0	.	-0.032	0.059	-0.020	-0.016	-0.048	0.018
24	.	0	.	-0.004	-0.058	-0.053	-0.046	-0.025	0.012
30	43.30	5	<.0001	-0.007	0.054	0.015	0.036	-0.004	0.055
36	47.55	11	<.0001	-0.014	0.009	-0.007	-0.049	0.016	0.029
42	52.04	17	<.0001	0.013	0.014	-0.011	0.008	0.012	-0.058
48	64.93	23	<.0001	-0.053	-0.004	-0.031	-0.061	0.045	-0.046

Lampiran 69. *Syntax Double Seasonal ARIMA pada Window 7 dengan Seleksi Input Random Forest.*

```

data listrik;
input y;
datalines;
4080.7
4033.9
4013.4
:
4171.4
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate p=(1, 2, 3, 11, 14, 17, 19, 29, 48, 147, 239, 282, 286,
288, 324, 334, 335, 336, 337, 338, 351, 381, 382, 385) (0) (0)
q=(1) (48) (336) noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanDSARIMAmode17.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```

Lampiran 70. *Output Double Seasonal ARIMA pada Window 7 dengan Seleksi Input Random Forest.*

Maximum Likelihood Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.26080	0.13686	1.91	0.0567	1
MA2,1	0.72051	0.03444	20.92	<.0001	48
MA3,1	0.99830	45.22434	0.02	0.9824	336
AR1,1	0.14803	0.13501	1.10	0.2729	1
AR1,2	0.03109	0.03410	0.91	0.3618	2
AR1,3	0.05672	0.02579	2.20	0.0279	3
AR1,4	0.05169	0.02509	2.06	0.0394	11
AR1,5	0.07009	0.02535	2.76	0.0057	14
AR1,6	-0.07492	0.02555	-2.93	0.0034	17
AR1,7	-0.06173	0.02579	-2.39	0.0167	19
AR1,8	0.03596	0.02508	1.43	0.1517	29
AR1,9	-0.02433	0.03720	-0.65	0.5132	48
AR1,10	0.0042438	0.02686	0.16	0.8744	147
AR1,11	-0.04267	0.02817	-1.51	0.1299	239
AR1,12	-0.01315	0.02807	-0.47	0.6394	282
AR1,13	-0.0093853	0.02907	-0.32	0.7468	286
AR1,14	0.07646	0.02936	2.60	0.0092	288
AR1,15	0.02234	0.02834	0.79	0.4305	324
AR1,16	-0.07084	0.03221	-2.20	0.0279	334
AR1,17	-0.02979	0.03418	-0.87	0.3835	335
AR1,18	0.07731	0.07194	1.07	0.2826	336
AR1,19	-0.05852	0.03670	-1.59	0.1109	337
AR1,20	-0.02476	0.03439	-0.72	0.4714	338
AR1,21	-0.02330	0.02860	-0.81	0.4153	351
AR1,22	0.01870	0.02855	0.65	0.5125	381
AR1,23	-0.01345	0.02875	-0.47	0.6398	382
AR1,24	-0.02320	0.02847	-0.81	0.4152	385
Variance Estimate			1620.777		
Std Error Estimate			40.25888		
AIC			11305.8		
SBC			11439.75		
Number of Residuals			1055		

Lampiran 70. *Output Double Seasonal ARIMA pada Window 7 dengan Seleksi Input Random Forest (Lanjutan).*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	Pr > DF	ChiSq	-----Autocorrelations-----					
6	.	0	.	0.002	0.004	-0.022	0.029	0.042	0.070
12	.	0	.	-0.034	-0.004	0.032	0.064	0.007	-0.056
18	.	0	.	-0.028	-0.009	-0.018	-0.025	0.017	-0.043
24	.	0	.	0.021	-0.063	-0.048	-0.044	-0.037	-0.004
30	46.13	3	<.0001	-0.009	0.054	0.018	0.034	-0.020	0.081
36	48.41	9	<.0001	-0.008	0.022	-0.016	-0.026	0.004	0.024
42	57.01	15	<.0001	-0.016	-0.018	-0.037	-0.016	0.021	-0.072
48	69.98	21	<.0001	-0.047	-0.011	-0.004	-0.068	0.049	-0.049

Lampiran 71. *Output Time Series Regression Window 1 dengan Seleksi Input Menggunakan Metode Stepwise.*

The regression equation is

$$\begin{aligned}
 Y(t) = & 4567 H4 + 4216 H6 + 4568 H5 + 4508 H2 + 4573 H3 + 4224 \\
 & H1 + 4026 H7 + 578 D36 + 557 D37 + 521 D38 + 510 D39 + \\
 & 460 D40 + 406 D35 + 395 D41 + 274 D42 - 700 D14 - 716 \\
 & D13 - 700 D7 - 698 D6 - 672 D5 - 646 D8 - 553 D15 - 638 \\
 & D4 - 575 D12 - 596 D3 - 565 D2 - 521 D9 - 519 D1 - 371 \\
 & D16 - 415 D11 - 364 D48 - 368 D10 + 119 D43 - 277 D47 - \\
 & 201 D17 - 134 D24 - 432 M18 - 163 D25 - 550 M19 - 540 \\
 & M20 - 187 D46 - 491 M21 - 481 M30 - 568 M29 - 466 M23 - \\
 & 466 M22 - 458 M26 - 576 M28 - 598 M27 - 451 M31 - 431 \\
 & M32 - 368 M33 - 140 D18 - 383 M17 + 142 D27 - 357 M24 \\
 & - 296 M25 + 119 D28 - 254 M16 - 219 M34 + 403 S5 + 401 \\
 & S2 + 390 S4 + 383 S3 + 377 S7 + 378 S1 + 367 S6 + \\
 & 319 S12 + 360 S8 + 315 S10 + 350 S9 + 302 S11 + 92,5 D29 \\
 & - 75,3 D45 - 226 J3 + 227 S13 + 321 M1 + 309 M3 + 306 M4 \\
 & + 305 M6 + 301 M5 + 299 M2 + 294 M7 + 271 M8 + 231 M9
 \end{aligned}$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H4	4566,74	16,04	284,71	0,000
H6	4215,98	18,97	222,30	0,000
H5	4568,08	16,13	283,28	0,000
H2	4508,20	17,26	261,17	0,000
H3	4573,41	17,26	264,95	0,000
H1	4224,30	17,26	244,72	0,000
H7	4025,51	25,92	155,32	0,000

**Lampiran 71. Output Time Series Regression Window 1 dengan
Seleksi Input Menggunakan Metode Stepwise
(Lanjutan).**

D36	578,05	37,86	15,27	0,000
D37	557,32	37,86	14,72	0,000
D38	521,46	37,86	13,77	0,000
D39	509,69	37,86	13,46	0,000
D40	459,97	37,86	12,15	0,000
D35	406,44	37,86	10,74	0,000
D41	394,61	37,86	10,42	0,000
D42	273,89	37,86	7,23	0,000
D14	-699,80	37,86	-18,48	0,000
D13	-715,67	40,53	-17,66	0,000
D7	-699,81	43,66	-16,03	0,000
D6	-698,38	43,66	-15,99	0,000
D5	-672,32	43,66	-15,40	0,000
D8	-645,71	43,66	-14,79	0,000
D15	-552,55	37,86	-14,59	0,000
D4	-638,41	43,66	-14,62	0,000
D12	-574,77	40,53	-14,18	0,000
D3	-596,42	43,66	-13,66	0,000
D2	-565,40	43,66	-12,95	0,000
D9	-520,77	43,66	-11,93	0,000
D1	-518,74	43,66	-11,88	0,000
D16	-370,89	40,32	-9,20	0,000
D11	-414,91	40,53	-10,24	0,000
D48	-363,86	37,86	-9,61	0,000
D10	-367,99	40,53	-9,08	0,000
D43	119,23	37,86	3,15	0,002
D47	-277,39	37,86	-7,33	0,000
D17	-201,26	40,32	-4,99	0,000
D24	-133,96	44,62	-3,00	0,003
M18	-432,3	108,8	-3,98	0,000
D25	-163,30	40,32	-4,05	0,000
M19	-549,8	102,1	-5,38	0,000
M20	-540,1	102,1	-5,29	0,000
D46	-187,26	37,86	-4,95	0,000
M21	-491,0	102,1	-4,81	0,000
M30	-480,6	102,1	-4,71	0,000
M29	-567,7	108,8	-5,22	0,000
M23	-466,4	102,1	-4,57	0,000
M22	-466,3	102,1	-4,57	0,000
M26	-457,7	102,1	-4,48	0,000
M28	-575,7	108,8	-5,29	0,000
M27	-598,3	108,8	-5,50	0,000
M31	-450,8	102,1	-4,41	0,000

**Lampiran 71. Output Time Series Regression Window 1 dengan
Seleksi Input Menggunakan Metode Stepwise
(Lanjutan).**

M32	-430,7	102,1	-4,22	0,000
M33	-367,7	102,1	-3,60	0,000
D18	-140,21	40,32	-3,48	0,001
M17	-382,8	108,8	-3,52	0,000
D27	142,28	40,32	3,53	0,000
M24	-356,8	110,4	-3,23	0,001
M25	-295,9	108,8	-2,72	0,007
D28	118,90	40,32	2,95	0,003
M16	-254,0	108,8	-2,34	0,020
M34	-218,5	102,1	-2,14	0,033
S5	402,6	108,9	3,70	0,000
S2	400,6	108,9	3,68	0,000
S4	390,4	108,9	3,58	0,000
S3	383,4	108,9	3,52	0,000
S7	377,2	108,9	3,46	0,001
S1	377,7	108,9	3,47	0,001
S6	367,0	108,9	3,37	0,001
S12	319,0	107,7	2,96	0,003
S8	359,8	108,9	3,30	0,001
S10	315,3	107,7	2,93	0,003
S9	350,4	108,9	3,22	0,001
S11	302,1	107,7	2,81	0,005
D29	92,55	40,32	2,30	0,022
D45	-75,33	37,86	-1,99	0,047
J3	-226,32	99,39	-2,28	0,023
S13	226,7	107,7	2,11	0,035
M1	321,1	110,0	2,92	0,004
M3	308,8	110,0	2,81	0,005
M4	306,0	110,0	2,78	0,005
M6	304,8	110,0	2,77	0,006
M5	300,9	110,0	2,73	0,006
M2	298,9	110,0	2,72	0,007
M7	294,3	110,0	2,68	0,008
M8	271,4	110,0	2,47	0,014
M9	231,3	110,0	2,10	0,036

S = 197,613

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	85	26319111330	309636604	7929,07	0,000
Residual Error	1355	52913872	39051		
Total	1440	26372025202			

Lampiran 72. *Output Time Series Regression Window 2 dengan Seleksi Input Menggunakan Metode Stepwise.*

The regression equation is
Y(t) = - 0,0368 t + 4594 H5 + 4535 H2 + 4249 H1 + 4231 H6 +
4602 H3 + 4622 H4+ 4062 H7 + 577 D36 + 557 D37 + 519
D38 + 509 D39 + 458 D40 + 435 D35 + 394 D41 + 272 D42 -
731 D14 - 720 D13 - 702 D7 - 699 D6 - 673 D5 - 647 D8 -
550 D15 - 643 D4 - 583 D12 - 601 D3 - 568 D2 - 525 D9 -
522 D1 - 369 D16 - 422 D11 - 365 D48 - 374 D10 - 281
D47 + 115 D43 - 201 D17 - 127 D24 - 451 M18 - 163 D25 -
563 M19 - 554 M20 - 190 D46 - 504 M21- 494 M30 - 617
M29 - 480 M23 - 480 M22 - 471 M26 - 622 M28 - 601 M27
- 464 M31 - 444 M32 - 381 M33 - 397 M17 - 135 D18 - 377
M24 + 131 D27 - 309 M25 + 152 D28 - 214 S28 - 270 M16 +
397 S5 + 393 S2 - 232 M34+ 389 S4 + 382 S3 + 379 S1 +
372 S7 + 362 S9 + 326 S12 + 324 S10 + 360 S8+ 365 S6 +
310 S11 - 213 M35 + 242 S13 - 77,3 D45 - 233 J3 + 206
S14+ 128 D29 - 220 S29 + 310 M1 + 300 M3 + 297 M4 + 291
M6 + 288 M5 + 288 M2 + 282 M7 + 259 M8 + 221 M9

Predictor	Coef	SE Coef	T	P
Noconstant				
t	-0,03685	0,01255	-2,94	0,003
H5	4593,90	18,30	251,07	0,000
H2	4534,76	19,43	233,42	0,000
H1	4249,09	19,15	221,85	0,000
H6	4230,58	20,10	210,50	0,000
H3	4601,74	19,72	233,39	0,000
H4	4621,72	20,02	230,86	0,000
H7	4061,89	27,46	147,93	0,000
D36	577,32	37,57	15,37	0,000
D37	556,92	37,57	14,82	0,000
D38	518,99	37,57	13,81	0,000
D39	508,76	37,57	13,54	0,000
D40	457,58	37,57	12,18	0,000
D35	435,39	40,00	10,88	0,000
D41	393,85	37,57	10,48	0,000
D42	271,99	37,57	7,24	0,000
D14	-731,19	40,99	-17,84	0,000
D13	-720,17	40,99	-17,57	0,000
D7	-701,56	44,31	-15,83	0,000
D6	-698,83	44,31	-15,77	0,000
D5	-673,33	44,31	-15,20	0,000
D8	-647,46	44,31	-14,61	0,000
D15	-549,83	37,57	-14,64	0,000

**Lampiran 72. *Output Time Series Regression Window 2* dengan
Seleksi Input Menggunakan Metode *Stepwise*
(Lanjutan).**

D4	-643,04	44,31	-14,51	0,000
D12	-582,97	40,99	-14,22	0,000
D3	-601,48	44,31	-13,58	0,000
D2	-568,34	44,31	-12,83	0,000
D9	-524,80	44,31	-11,85	0,000
D1	-521,54	44,31	-11,77	0,000
D16	-368,84	40,00	-9,22	0,000
D11	-422,24	40,99	-10,30	0,000
D48	-365,39	37,57	-9,73	0,000
D10	-373,65	40,99	-9,12	0,000
D47	-280,55	37,57	-7,47	0,000
D43	115,37	37,57	3,07	0,002
D17	-200,62	40,00	-5,02	0,000
D24	-127,12	44,27	-2,87	0,004
M18	-450,7	108,0	-4,17	0,000
D25	-163,22	40,00	-4,08	0,000
M19	-563,4	101,5	-5,55	0,000
M20	-553,6	101,5	-5,45	0,000
D46	-189,59	37,57	-5,05	0,000
M21	-504,5	101,5	-4,97	0,000
M30	-493,8	101,5	-4,87	0,000
M29	-616,6	109,7	-5,62	0,000
M23	-479,8	101,5	-4,73	0,000
M22	-479,8	101,5	-4,73	0,000
M26	-471,0	101,5	-4,64	0,000
M28	-621,5	109,7	-5,67	0,000
M27	-600,6	108,0	-5,56	0,000
M31	-464,0	101,5	-4,57	0,000
M32	-443,8	101,5	-4,37	0,000
M33	-380,8	101,5	-3,75	0,000
M17	-397,1	108,0	-3,68	0,000
D18	-135,43	40,00	-3,39	0,001
M24	-377,0	109,7	-3,44	0,001
D27	131,33	40,00	3,28	0,001
M25	-309,3	108,0	-2,86	0,004
D28	151,52	44,30	3,42	0,001
S28	-214,34	99,07	-2,16	0,031
M16	-269,7	108,0	-2,50	0,013
S5	397,10	99,07	4,01	0,000
S2	392,93	99,07	3,97	0,000
M34	-231,6	101,5	-2,28	0,023
S4	388,61	99,07	3,92	0,000
S3	382,15	99,07	3,86	0,000

**Lampiran 72. *Output Time Series Regression Window 2* dengan
Seleksi Input Menggunakan Metode *Stepwise*
(Lanjutan).**

S1	378,57	99,07	3,82	0,000
S7	372,29	99,07	3,76	0,000
S9	361,80	99,07	3,65	0,000
S12	325,86	97,59	3,34	0,001
S10	324,01	97,59	3,32	0,001
S8	360,49	99,07	3,64	0,000
S6	365,05	99,07	3,68	0,000
S11	310,30	97,59	3,18	0,002
M35	-213,3	108,0	-1,97	0,049
S13	242,04	97,59	2,48	0,013
D45	-77,33	37,57	-2,06	0,040
J3	-233,33	98,62	-2,37	0,018
S14	205,84	97,59	2,11	0,035
D29	128,31	44,30	2,90	0,004
S29	-219,66	99,07	-2,22	0,027
M1	309,6	109,7	2,82	0,005
M3	299,7	109,7	2,73	0,006
M4	296,5	109,7	2,70	0,007
M6	291,2	109,7	2,66	0,008
M5	287,8	109,7	2,62	0,009
M2	287,6	109,7	2,62	0,009
M7	282,1	109,7	2,57	0,010
M8	259,2	109,7	2,36	0,018
M9	221,4	109,7	2,02	0,044

S = 196,050

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	90	26220353824	291337265	7579,85	0,000
Residual Error	1350	51888266	38436		
Total	1440	26272242090			

**Lampiran 73. Output Time Series Regression Window 3 dengan
Seleksi Input Menggunakan Metode Stepwise.**

The regression equation is

$$\begin{aligned}
 Y(t) = & -0,0577 t + 4548 H2 + 4261 H1 + 4616 H3 + 4244 H6 + \\
 & 4637 H4 + 4631 H5 + 4055 H7 + 576 D36 + 557 D37 + 520 \\
 & D38 + 509 D39 + 460 D40 + 409 D35 + 394 D41 + 272 D42 - \\
 & 729 D14 - 718 D13 + 117 D43 - 705 D7 - 702 D6 - 677 D5 \\
 & - 555 D15 - 649 D8 - 647 D4 - 578 D12 - 604 D3 - 571 D2 \\
 & - 528 D9 - 369 D16 - 525 D1 - 419 D11 - 361 D48 - 370 \\
 & D10 - 277 D47 - 204 D17 - 440 M18 - 550 M19 - 128 D24 - \\
 & 535 M20 - 159 D25 - 492 M30 - 609 M29 - 479 M21 - 471 \\
 & M26 - 470 M23 - 470 M22 - 595 M27 - 614 M28 - 186 D46 \\
 & - 455 M31 - 428 M32 - 362 M33 - 382 M17 - 137 D18 - 72 \\
 & M24 - 314 M25 + 128 D27 - 256 M16 - 205 M34 + 400 S5 + \\
 & 395 S2 + 392 S4 + 383 S3 + 320 S12 + 319 S10 + 364 S9 + \\
 & 381 S1 + 375 S7 + 361 S8 + 306 S11 + 368 S6 + 151 D28 + \\
 & 239 S13 - 74,1 D45 + 320 M1 + 203 S14 + 307 M6 + 305 M4 \\
 & + 305 M3 + 302 M5 + 301 M2 + 296 M7 + 268 M8 - 240 J3 + \\
 & 228 M9 - 215 S28 + 128 D29 - 220 S29
 \end{aligned}$$

Predictor	Coef	SE Coef	T	P
Noconstant				
t	-0,05773	0,01251	-4,61	0,000
H2	4547,66	19,18	237,16	0,000
H1	4260,99	18,92	225,23	0,000
H3	4615,65	19,45	237,33	0,000
H6	4244,05	19,81	214,20	0,000
H4	4636,62	19,74	234,94	0,000
H5	4630,94	20,13	230,10	0,000
H7	4054,86	25,64	158,18	0,000
D36	576,10	37,52	15,35	0,000
D37	557,21	37,52	14,85	0,000
D38	520,00	37,52	13,86	0,000
D39	509,24	37,52	13,57	0,000
D40	459,95	37,52	12,26	0,000
D35	408,59	37,52	10,89	0,000
D41	393,81	37,52	10,50	0,000
D42	272,24	37,52	7,26	0,000
D14	-729,39	40,94	-17,82	0,000
D13	-717,58	40,94	-17,53	0,000
D43	117,10	37,52	3,12	0,002
D7	-704,90	45,23	-15,59	0,000
D6	-702,42	45,23	-15,53	0,000
D5	-677,08	45,23	-14,97	0,000
D15	-555,12	37,52	-14,80	0,000

**Lampiran 73. Output Time Series Regression Window 3 dengan
Seleksi Input Menggunakan Metode Stepwise
(Lanjutan).**

D8	-648,51	45,23	-14,34	0,000
D4	-647,36	45,23	-14,31	0,000
D12	-578,44	40,94	-14,13	0,000
D3	-603,73	45,23	-13,35	0,000
D2	-571,39	45,23	-12,63	0,000
D9	-527,93	45,23	-11,67	0,000
D16	-369,38	40,64	-9,09	0,000
D1	-525,41	45,23	-11,62	0,000
D11	-419,23	40,94	-10,24	0,000
D48	-360,87	37,52	-9,62	0,000
D10	-369,57	40,94	-9,03	0,000
D47	-276,93	37,52	-7,38	0,000
D17	-203,82	40,64	-5,01	0,000
M18	-439,71	98,08	-4,48	0,000
M19	-549,93	90,57	-6,07	0,000
D24	-127,78	44,15	-2,89	0,004
M20	-534,90	90,57	-5,91	0,000
D25	-159,15	40,64	-3,92	0,000
M30	-492,04	90,57	-5,43	0,000
M29	-608,8	100,0	-6,09	0,000
M21	-479,22	90,57	-5,29	0,000
M26	-471,43	90,57	-5,21	0,000
M23	-470,12	90,57	-5,19	0,000
M22	-469,56	90,57	-5,18	0,000
M27	-594,57	98,08	-6,06	0,000
M28	-613,7	100,0	-6,13	0,000
D46	-186,17	37,52	-4,96	0,000
M31	-455,32	90,57	-5,03	0,000
M32	-427,66	90,57	-4,72	0,000
M33	-361,57	90,57	-3,99	0,000
M17	-381,61	98,08	-3,89	0,000
D18	-136,97	40,64	-3,37	0,001
M24	-372,43	99,58	-3,74	0,000
M25	-314,18	98,08	-3,20	0,001
D27	128,24	40,64	3,16	0,002
M16	-256,39	98,08	-2,61	0,009
M34	-204,71	90,57	-2,26	0,024
S5	399,76	99,19	4,03	0,000
S2	394,82	99,19	3,98	0,000
S4	391,80	99,19	3,95	0,000
S3	383,25	99,19	3,86	0,000
S12	320,38	97,25	3,29	0,001
S10	318,93	97,25	3,28	0,001

**Lampiran 73. Output Time Series Regression Window 3 dengan
Seleksi Input Menggunakan Metode Stepwise
(Lanjutan).**

S9	363,92	99,19	3,67	0,000
S1	381,26	99,19	3,84	0,000
S7	374,57	99,19	3,78	0,000
S8	360,50	99,19	3,63	0,000
S11	306,31	97,25	3,15	0,002
S6	367,55	99,19	3,71	0,000
D28	151,18	45,23	3,34	0,001
S13	238,52	97,25	2,45	0,014
D45	-74,14	37,52	-1,98	0,048
M1	320,1	100,0	3,20	0,001
S14	203,13	97,25	2,09	0,037
M6	307,0	100,0	3,07	0,002
M4	305,4	100,0	3,05	0,002
M3	305,0	100,0	3,05	0,002
M5	301,7	100,0	3,02	0,003
M2	301,5	100,0	3,01	0,003
M7	296,1	100,0	2,96	0,003
M8	267,7	100,0	2,68	0,008
J3	-240,2	107,7	-2,23	0,026
M9	228,1	100,0	2,28	0,023
S28	-214,61	99,19	-2,16	0,031
D29	128,20	45,23	2,83	0,005
S29	-220,15	99,19	-2,22	0,027

S = 195,361

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	89	25956452271	291645531	7641,53	0,000
Residual Error	1351	51562087	38166		
Total	1440	26008014358			

Lampiran 74. *Output Time Series Regression Window 4 dengan Seleksi Input Menggunakan Metode Stepwise.*

$$\begin{aligned} Y(t) = & -0,0488 t + 4549 H2 + 4616 H3 + 4637 H4 + 4631 H5 + \\ & 4282 H1 + 4064 H7 + 4234 H6 + 566 D36 + 547 D37 + 512 \\ & D38 + 501 D39 + 452 D40 + 438 D35 + 385 D41 + 263 D42 - \\ & 742 D14 - 731 D13 - 724 D7 - 721 D6 - 696 D5 - 570 D15 \\ & - 666 D8 - 667 D4 - 593 D12 - 623 D3 - 591 D2 - 544 D9 \\ & - 545 D1 - 381 D16 - 435 D11 - 370 D48 - 386 D10 + 105 \\ & D43 - 286 D47 - 211 D17 - 451 M18 - 568 M19 - 133 D24 - \\ & 553 M20 - 165 D25 - 510 M30 - 594 M29 - 196 D46 - 497 \\ & M21 - 490 M26 - 488 M23 - 488 M22 - 615 M27 - 595 M28 \\ & - 474 M31 - 446 M32 - 380 M33 - 393 M17 - 144 D18 - 385 \\ & M24 - 327 M25 + 130 D27 - 263 M16 - 223 M34 + 114 D28 - \\ & 84,0 D45 - 196 M35 + 430 S4 + 428 S5 + 425 S2 + 426 S3 \\ & + 422 S1 + 395 S9 + 397 S8 + 404 S6 + 400 S7 + 331 S12 + \\ & 331 S10 + 311 S11 + 322 M1 + 95,0 D29 + 307 M6 + 307 M4 \\ & + 306 M3 + 303 M2 + 303 M5 + 297 M7 + 267 M8 + 226 M9 - \\ & 244 J3 + 236 S13 + 225 S14 \end{aligned}$$

Predictor	Coef	SE Coef	T	P
Noconstant				
t	-0,04876	0,01260	-3,87	0,000
H2	4548,53	19,02	239,11	0,000
H3	4616,09	19,28	239,40	0,000
H4	4636,63	19,56	237,08	0,000
H5	4630,60	19,94	232,26	0,000
H1	4281,91	18,65	229,62	0,000
H7	4064,12	26,05	156,03	0,000
H6	4234,26	21,75	194,67	0,000
D36	565,75	37,81	14,96	0,000
D37	547,38	37,81	14,48	0,000
D38	511,58	37,81	13,53	0,000
D39	501,11	37,81	13,25	0,000
D40	452,30	37,81	11,96	0,000
D35	437,61	40,95	10,69	0,000
D41	385,05	37,81	10,18	0,000
D42	262,71	37,81	6,95	0,000
D14	-741,95	40,48	-18,33	0,000
D13	-730,55	40,48	-18,05	0,000
D7	-723,54	44,50	-16,26	0,000
D6	-721,01	44,50	-16,20	0,000
D5	-696,02	44,50	-15,64	0,000
D15	-569,78	37,81	-15,07	0,000
D8	-666,21	44,50	-14,97	0,000
D4	-666,98	44,50	-14,99	0,000

Lampiran 74. *Output Time Series Regression Window 4 dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*

D12	-593,22	40,48	-14,66	0,000
D3	-623,10	44,50	-14,00	0,000
D2	-591,01	44,50	-13,28	0,000
D9	-543,70	44,50	-12,22	0,000
D1	-544,95	44,50	-12,25	0,000
D16	-380,94	40,95	-9,30	0,000
D11	-435,36	40,48	-10,76	0,000
D48	-369,95	37,81	-9,78	0,000
D10	-385,79	40,48	-9,53	0,000
D43	105,28	37,81	2,78	0,005
D47	-286,15	37,81	-7,57	0,000
D17	-210,74	40,95	-5,15	0,000
M18	-450,72	98,93	-4,56	0,000
M19	-568,17	91,37	-6,22	0,000
D24	-133,32	44,48	-3,00	0,003
M20	-553,14	91,37	-6,05	0,000
D25	-165,02	40,95	-4,03	0,000
M30	-510,37	91,37	-5,59	0,000
M29	-593,99	98,93	-6,00	0,000
D46	-196,36	37,81	-5,19	0,000
M21	-497,47	91,37	-5,44	0,000
M26	-489,72	91,37	-5,36	0,000
M23	-488,39	91,37	-5,35	0,000
M22	-487,82	91,37	-5,34	0,000
M27	-615,09	98,93	-6,22	0,000
M28	-595,31	98,93	-6,02	0,000
M31	-473,66	91,37	-5,18	0,000
M32	-446,01	91,37	-4,88	0,000
M33	-379,92	91,37	-4,16	0,000
M17	-392,91	98,93	-3,97	0,000
D18	-144,18	40,95	-3,52	0,000
M24	-385,2	100,4	-3,83	0,000
M25	-326,59	98,93	-3,30	0,001
D27	130,46	40,95	3,19	0,001
M16	-263,04	98,93	-2,66	0,008
M34	-223,07	91,37	-2,44	0,015
D28	114,48	40,95	2,80	0,005
D45	-84,01	37,81	-2,22	0,026
M35	-195,98	98,93	-1,98	0,048
S4	429,9	108,9	3,95	0,000
S5	427,9	108,9	3,93	0,000
S2	425,4	108,9	3,90	0,000
S3	425,9	108,9	3,91	0,000

Lampiran 74. *Output Time Series Regression Window 4 dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*

S1	422,3	108,9	3,88	0,000
S9	395,1	108,9	3,63	0,000
S8	396,9	108,9	3,64	0,000
S6	404,4	108,9	3,71	0,000
S7	400,4	108,9	3,68	0,000
S12	331,2	107,3	3,09	0,002
S10	330,7	107,3	3,08	0,002
S11	311,4	107,3	2,90	0,004
M1	321,6	100,4	3,20	0,001
D29	95,03	40,95	2,32	0,020
M6	307,5	100,4	3,06	0,002
M4	306,9	100,4	3,06	0,002
M3	306,3	100,4	3,05	0,002
M2	303,0	100,4	3,02	0,003
M5	302,5	100,4	3,01	0,003
M7	296,6	100,4	2,95	0,003
M8	267,3	100,4	2,66	0,008
M9	225,7	100,4	2,25	0,025
J3	-244,0	108,5	-2,25	0,025
S13	236,1	107,3	2,20	0,028
S14	224,5	107,3	2,09	0,037

S = 196,823

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	88	25953981395	294931607	7613,22	0,000
Residual Error	1352	52375653	38739		
Total	1440	26006357049			

**Lampiran 75. Output Time Series Regression Window 5 dengan
Seleksi Input Menggunakan Metode Stepwise.**

The regression equation is

$$\begin{aligned}
 Y(t) = & -0,0505 t + 4622 H3 + 4643 H4 + 4545 H2 + 4637 H5 + \\
 & 4288 H1 + 4239 H6 + 4058 H7 + 562 D36 + 545 D37 + 508 \\
 & D38 + 501 D39 + 449 D40 + 435 D35 + 380 D41 + 257 D42 - \\
 & 750 D14 - 744 D13 - 733 D7 - 731 D6 - 706 D5 - 675 D8 - \\
 & 677 D4 - 571 D15 - 607 D12 - 633 D3 - 601 D2 - 551 D9 - \\
 & 554 D1 - 386 D16 - 450 D11 - 379 D48 - 400 D10 - 295 \\
 & D47 - 218 D17 + 97,7 D43 - 139 D24 - 444 M18 - 171 D25 \\
 & - 204 D46 - 478 M19 - 551 M20 - 509 M30 - 593 M29 - 489 \\
 & M21 - 487 M26 - 611 M27 - 486 M22 - 484 M23 - 590 M28 \\
 & - 478 M31 - 455 M32 - 151 D18 - 388 M33 - 380 M17 - 378 \\
 & M24 - 321 M25 + 125 D27 + 109 D28 - 255 M16 - 242 M34 + \\
 & 434 S4 + 432 S5 + 430 S2 + 430 S3 + 425 S1 + 397 S9 + \\
 & 408 S6 + 404 S7 + 400 S8 + 340 S12 + 339 S10 + 320 S11 \\
 & - 214 M35 - 89,8 D45 + 88,8 D29 + 337 M1 + 243 S13 - \\
 & 245 J3 + 324 M4 + 323 M6 + 323 M3 + 320 M5 + 316 M2 + \\
 & 308 M7 + 280 M8 + 236 M9 + 227 S14 - 82,2 D19
 \end{aligned}$$

Predictor	Coef	SE Coef	T	P
Noconstant				
t	-0,05048	0,01259	-4,01	0,000
H3	4622,10	19,20	240,70	0,000
H4	4642,73	19,46	238,58	0,000
H2	4545,08	18,83	241,33	0,000
H5	4636,80	19,82	233,90	0,000
H1	4288,05	18,54	231,31	0,000
H6	4239,11	21,64	195,85	0,000
H7	4058,41	28,48	142,51	0,000
D36	562,01	37,82	14,86	0,000
D37	544,52	37,82	14,40	0,000
D38	508,39	37,82	13,44	0,000
D39	500,98	37,82	13,25	0,000
D40	449,43	37,82	11,88	0,000
D35	435,31	40,25	10,82	0,000
D41	379,67	37,82	10,04	0,000
D42	256,93	37,82	6,79	0,000
D14	-750,45	40,47	-18,55	0,000
D13	-743,81	40,47	-18,38	0,000
D7	-733,48	43,57	-16,84	0,000
D6	-730,73	43,57	-16,77	0,000
D5	-706,49	43,57	-16,22	0,000
D8	-674,90	43,57	-15,49	0,000
D4	-677,46	43,57	-15,55	0,000

**Lampiran 75. *Output Time Series Regression Window 5* dengan
Seleksi Input Menggunakan Metode *Stepwise*
(Lanjutan).**

D15	-571,45	37,82	-15,11	0,000
D12	-607,48	40,47	-15,01	0,000
D3	-632,96	43,57	-14,53	0,000
D2	-601,23	43,57	-13,80	0,000
D9	-551,31	43,57	-12,65	0,000
D1	-553,90	43,57	-12,71	0,000
D16	-386,48	40,25	-9,60	0,000
D11	-449,52	40,47	-11,11	0,000
D48	-379,02	37,82	-10,02	0,000
D10	-400,00	40,47	-9,88	0,000
D47	-295,28	37,82	-7,81	0,000
D17	-218,08	40,25	-5,42	0,000
D43	97,66	37,82	2,58	0,010
D24	-139,44	43,54	-3,20	0,001
M18	-443,9	108,3	-4,10	0,000
D25	-170,93	40,25	-4,25	0,000
D46	-204,32	37,82	-5,40	0,000
M19	-478,5	108,3	-4,42	0,000
M20	-550,9	101,8	-5,41	0,000
M30	-509,3	101,8	-5,00	0,000
M29	-592,8	108,3	-5,47	0,000
M21	-489,0	101,8	-4,80	0,000
M26	-487,1	101,8	-4,78	0,000
M27	-610,5	108,3	-5,64	0,000
M22	-485,7	101,8	-4,77	0,000
M23	-483,6	101,8	-4,75	0,000
M28	-589,9	108,3	-5,45	0,000
M31	-477,9	101,8	-4,69	0,000
M32	-455,2	101,8	-4,47	0,000
D18	-150,80	40,25	-3,75	0,000
M33	-388,4	101,8	-3,81	0,000
M17	-380,0	108,3	-3,51	0,000
M24	-378,0	109,6	-3,45	0,001
M25	-320,8	108,3	-2,96	0,003
D27	124,66	40,25	3,10	0,002
D28	108,73	40,25	2,70	0,007
M16	-255,0	108,3	-2,35	0,019
M34	-242,0	101,8	-2,38	0,018
S4	434,4	108,4	4,01	0,000
S5	432,4	108,4	3,99	0,000
S2	429,7	108,4	3,96	0,000
S3	429,8	108,4	3,96	0,000
S1	425,3	108,4	3,92	0,000

Lampiran 75. Output Time Series Regression Window 5 dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).

S9	396,8	108,4	3,66	0,000
S6	408,2	108,4	3,77	0,000
S7	404,4	108,4	3,73	0,000
S8	399,7	108,4	3,69	0,000
S12	339,5	107,2	3,17	0,002
S10	339,0	107,2	3,16	0,002
S11	319,6	107,2	2,98	0,003
M35	-214,2	108,3	-1,98	0,048
D45	-89,78	37,82	-2,37	0,018
D29	88,77	40,25	2,21	0,028
M1	337,0	109,6	3,08	0,002
S13	243,5	107,2	2,27	0,023
J3	-245,1	108,0	-2,27	0,023
M4	324,3	109,6	2,96	0,003
M6	323,3	109,6	2,95	0,003
M3	323,2	109,6	2,95	0,003
M5	320,5	109,6	2,92	0,004
M2	316,1	109,6	2,88	0,004
M7	307,9	109,6	2,81	0,005
M8	279,7	109,6	2,55	0,011
M9	236,1	109,6	2,15	0,031
S14	227,1	107,2	2,12	0,034
D19	-82,21	40,25	-2,04	0,041

S = 196,598

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	89	26138695872	293693212	7598,66	0,000
Residual Error	1351	52217029	38651		
Total	1440	26190912901			

Lampiran 76. *Output Time Series Regression Window 6 dengan Seleksi Input Menggunakan Metode Stepwise.*

The regression equation is
Y(t) = 4606 H4 + 4504 H2 + 4597 H5 + 4582 H3 + 4200 H6 + 4187
H1 + 4016 H7 + 560 D36 + 542 D37 + 505 D38 + 498 D39 +
447 D40 + 436 D35 + 378 D41 + 255 D42 - 742 D14 - 736
D13 - 720 D7 - 717 D6 - 692 D5 - 661 D8 - 565 D15 - 662
D4 - 600 D12 - 618 D3 - 587 D2 - 538 D9 - 539 D1 - 383
D16 - 447 D11 - 381 D48 - 390 D10 - 298 D47 - 216 D17 +
94,3 D43 - 143 D24 - 447 M18 - 172 D25 - 206 D46 - 478
M19 - 550 M20 - 508 M30 - 592 M29 - 488 M21 - 486 M26 -
611 M27 - 484 M22 - 482 M23 - 586 M28 - 477 M31 - 454
M32 - 388 M33 - 147 D18 - 381 M17 - 374 M24 - 319 M25
+ 126 D27 + 106 D28 - 257 M16 - 241 M34 - 92,8 D45 -
214 M35 + 420 S4 + 419 S5 + 416 S2 + 416 S3 + 412 S1 +
384 S9 + 395 S6 + 391 S7 + 387 S8 + 333 S12 + 329 S10 +
317 S11 + 88,8 D29 + 325 M1 + 236 S13 - 239 J3 + 312 M6
+ 311 M4 + 311 M3 + 308 M5 + 304 M2 + 296 M7 + 268 M8 +
225 M9 + 219 S14 - 81,7 D19

Predictor	Coef	SE Coef	T	P
Noconstant				
H4	4605,69	16,89	272,74	0,000
H2	4504,40	15,74	286,24	0,000
H5	4597,21	16,99	270,65	0,000
H3	4581,57	15,74	291,14	0,000
H6	4200,46	18,66	225,09	0,000
H1	4187,21	16,89	247,96	0,000
H7	4016,07	25,61	156,82	0,000
D36	560,00	36,50	15,34	0,000
D37	541,99	36,50	14,85	0,000
D38	504,98	36,50	13,83	0,000
D39	498,48	36,50	13,66	0,000
D40	447,30	36,50	12,25	0,000
D35	435,99	38,85	11,22	0,000
D41	377,85	36,50	10,35	0,000
D42	254,56	36,50	6,97	0,000
D14	-741,90	39,06	-18,99	0,000
D13	-735,72	39,06	-18,84	0,000
D7	-719,77	42,05	-17,12	0,000
D6	-717,07	42,05	-17,05	0,000
D5	-691,81	42,05	-16,45	0,000
D8	-661,08	42,05	-15,72	0,000
D15	-565,35	36,50	-15,49	0,000
D4	-662,25	42,05	-15,75	0,000

**Lampiran 76. *Output Time Series Regression Window 6* dengan
Seleksi Input Menggunakan Metode *Stepwise*
(Lanjutan).**

D12	-600,44	39,06	-15,37	0,000
D3	-618,24	42,05	-14,70	0,000
D2	-586,57	42,05	-13,95	0,000
D9	-538,02	42,05	-12,79	0,000
D1	-539,36	42,05	-12,83	0,000
D16	-382,85	38,85	-9,85	0,000
D11	-446,56	39,06	-11,43	0,000
D48	-380,66	36,50	-10,43	0,000
D10	-389,56	39,06	-9,97	0,000
D47	-298,14	36,50	-8,17	0,000
D17	-215,95	38,85	-5,56	0,000
D43	94,35	36,50	2,58	0,010
D24	-142,57	42,03	-3,39	0,001
M18	-446,7	104,6	-4,27	0,000
D25	-171,50	38,85	-4,41	0,000
D46	-206,39	36,50	-5,65	0,000
M19	-477,6	104,6	-4,57	0,000
M20	-549,60	98,28	-5,59	0,000
M30	-508,50	98,28	-5,17	0,000
M29	-591,9	104,6	-5,66	0,000
M21	-487,72	98,28	-4,96	0,000
M26	-486,05	98,28	-4,95	0,000
M27	-611,1	104,6	-5,84	0,000
M22	-484,47	98,28	-4,93	0,000
M23	-482,40	98,28	-4,91	0,000
M28	-586,4	104,6	-5,61	0,000
M31	-477,15	98,28	-4,86	0,000
M32	-454,45	98,28	-4,62	0,000
M33	-387,72	98,28	-3,95	0,000
D18	-146,50	38,85	-3,77	0,000
M17	-380,6	104,6	-3,64	0,000
M24	-373,7	105,8	-3,53	0,000
M25	-319,1	104,6	-3,05	0,002
D27	126,25	38,85	3,25	0,001
D28	106,15	38,85	2,73	0,006
M16	-257,1	104,6	-2,46	0,014
M34	-241,32	98,28	-2,46	0,014
D45	-92,85	36,50	-2,54	0,011
M35	-214,3	104,6	-2,05	0,041
S4	420,1	104,6	4,01	0,000
S5	418,6	104,6	4,00	0,000
S2	416,1	104,6	3,98	0,000
S3	416,0	104,6	3,98	0,000

Lampiran 76. *Output Time Series Regression Window 6 dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*

S1	411,9	104,6	3,94	0,000
S9	384,1	104,6	3,67	0,000
S6	395,4	104,6	3,78	0,000
S7	391,5	104,6	3,74	0,000
S8	386,5	104,6	3,69	0,000
S12	333,0	103,4	3,22	0,001
S10	329,1	103,4	3,18	0,001
S11	317,2	103,4	3,07	0,002
D29	88,80	38,85	2,29	0,022
M1	324,8	105,8	3,07	0,002
S13	235,8	103,4	2,28	0,023
J3	-238,8	104,3	-2,29	0,022
M6	311,6	105,8	2,95	0,003
M4	311,2	105,8	2,94	0,003
M3	310,7	105,8	2,94	0,003
M5	307,9	105,8	2,91	0,004
M2	303,7	105,8	2,87	0,004
M7	296,2	105,8	2,80	0,005
M8	267,9	105,8	2,53	0,011
M9	224,7	105,8	2,12	0,034
S14	219,0	103,4	2,12	0,034
D19	-81,65	38,85	-2,10	0,036

S = 189,761

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	88	26162117203	297296786	8256,14	0,000
Residual Error	1352	48684388	36009		
Total	1440	26210801592			

**Lampiran 77. Output Time Series Regression Window 7 dengan
Seleksi Input Menggunakan Metode Stepwise.**

The regression equation is

$$\begin{aligned}
 Y(t) = & 4598 H5 + 4582 H3 + 4602 H4 + 4200 H6 + 4485 H2 + 4188 \\
 & H1 + 4017 H7 + 559 D36 + 542 D37 + 505 D38 + 497 D39 + \\
 & 447 D40 + 440 D35 + 378 D41 + 254 D42 - 744 D14 - 739 \\
 & D13 - 721 D7 - 719 D6 - 692 D5 - 660 D8 - 566 D15 - 662 \\
 & D4 - 605 D12 - 620 D3 - 590 D2 - 537 D9 - 542 D1 - 383 \\
 & D16 - 451 D11 - 379 D48 - 390 D10 - 298 D47 - 217 D17 + \\
 & 94,1 D43 - 139 D24 - 447 M18 - 170 D25 - 205 D46 - 479 \\
 & M19 - 550 M20 - 509 M30 - 592 M29 - 489 M21 - 487 M26 - \\
 & 611 M27 - 485 M22 - 483 M23 - 586 M28 - 478 M31 - 455 \\
 & M32 - 389 M33 - 147 D18 - 380 M17 - 378 M24 - 321 M25 \\
 & + 125 D27 + 105 D28 - 257 M16 - 242 M34 - 91,5 D45 - \\
 & 219 M35 + 420 S2 + 420 S4 + 419 S5 + 417 S3 + 414 S1 + \\
 & 398 S6 + 383 S9 + 393 S7 + 385 S8 + 338 S12 + 329 S10 + \\
 & 322 S11 + 88,3 D29 + 239 S13 - 243 J3 + 326 M1 + 313 M6 \\
 & + 311 M3 + 310 M4 + 308 M5 + 307 M2 + 297 M7 + 266 M8 + \\
 & 221 S14 + 223 M9 - 80,7 D19
 \end{aligned}$$

Predictor	Coef	SE Coef	T	P
Noconstant				
H5	4597,71	16,92	271,74	0,000
H3	4581,98	15,68	292,31	0,000
H4	4601,76	15,68	293,57	0,000
H6	4200,33	18,59	225,96	0,000
H2	4485,01	16,82	266,64	0,000
H1	4187,63	16,82	248,96	0,000
H7	4016,86	25,51	157,47	0,000
D36	559,21	36,36	15,38	0,000
D37	541,97	36,36	14,91	0,000
D38	504,51	36,36	13,88	0,000
D39	497,37	36,36	13,68	0,000
D40	446,97	36,36	12,29	0,000
D35	439,87	38,70	11,37	0,000
D41	378,03	36,36	10,40	0,000
D42	254,26	36,36	6,99	0,000
D14	-744,19	38,91	-19,13	0,000
D13	-739,19	38,91	-19,00	0,000
D7	-721,03	41,89	-17,21	0,000
D6	-719,14	41,89	-17,17	0,000
D5	-692,46	41,89	-16,53	0,000
D8	-659,68	41,89	-15,75	0,000
D15	-565,63	36,36	-15,56	0,000
D4	-662,24	41,89	-15,81	0,000

**Lampiran 77. *Output Time Series Regression Window 7* dengan
Seleksi Input Menggunakan Metode *Stepwise*
(Lanjutan).**

D12	-605,17	38,91	-15,55	0,000
D3	-619,52	41,89	-14,79	0,000
D2	-590,43	41,89	-14,10	0,000
D9	-537,22	41,89	-12,82	0,000
D1	-541,68	41,89	-12,93	0,000
D16	-383,32	38,70	-9,91	0,000
D11	-451,24	38,91	-11,60	0,000
D48	-379,50	36,36	-10,44	0,000
D10	-389,65	38,91	-10,01	0,000
D47	-297,84	36,36	-8,19	0,000
D17	-217,09	38,70	-5,61	0,000
D43	94,06	36,36	2,59	0,010
D24	-139,11	41,87	-3,32	0,001
M18	-446,9	104,2	-4,29	0,000
D25	-170,43	38,70	-4,40	0,000
D46	-205,42	36,36	-5,65	0,000
M19	-479,3	104,2	-4,60	0,000
M20	-550,38	97,89	-5,62	0,000
M30	-509,28	97,89	-5,20	0,000
M29	-592,2	104,2	-5,69	0,000
M21	-488,51	97,89	-4,99	0,000
M26	-486,83	97,89	-4,97	0,000
M27	-610,9	104,2	-5,87	0,000
M22	-485,26	97,89	-4,96	0,000
M23	-483,18	97,89	-4,94	0,000
M28	-585,7	104,2	-5,62	0,000
M31	-477,93	97,89	-4,88	0,000
M32	-455,23	97,89	-4,65	0,000
M33	-388,51	97,89	-3,97	0,000
D18	-147,14	38,70	-3,80	0,000
M17	-380,2	104,2	-3,65	0,000
M24	-378,0	105,4	-3,59	0,000
M25	-321,0	104,2	-3,08	0,002
D27	125,30	38,70	3,24	0,001
D28	104,65	38,70	2,70	0,007
M16	-257,4	104,2	-2,47	0,014
M34	-242,11	97,89	-2,47	0,014
D45	-91,54	36,36	-2,52	0,012
M35	-218,9	104,2	-2,10	0,036
S4	420,2	104,2	4,03	0,000
S5	419,4	104,2	4,02	0,000
S3	417,4	104,2	4,00	0,000
S1	414,3	104,2	3,97	0,000

**Lampiran 77. Output Time Series Regression Window 7 dengan
Seleksi Input Menggunakan Metode Stepwise
(Lanjutan).**

S6	397,6	104,2	3,81	0,000
S9	383,5	104,2	3,68	0,000
S7	392,8	104,2	3,77	0,000
S8	385,3	104,2	3,70	0,000
S12	337,8	103,0	3,28	0,001
S10	329,4	103,0	3,20	0,001
S11	322,0	103,0	3,12	0,002
D29	88,31	38,70	2,28	0,023
S13	239,4	103,0	2,32	0,020
J3	-242,7	103,8	-2,34	0,020
M1	326,3	105,4	3,10	0,002
M6	312,9	105,4	2,97	0,003
M3	311,2	105,4	2,95	0,003
M4	310,4	105,4	2,95	0,003
M5	307,8	105,4	2,92	0,004
M2	306,8	105,4	2,91	0,004
M7	296,6	105,4	2,82	0,005
M8	265,7	105,4	2,52	0,012
S14	221,4	103,0	2,15	0,032
M9	223,1	105,4	2,12	0,034
D19	-80,74	38,70	-2,09	0,037


S = 189,021

Analysis of Variance


Source	DF	SS	MS	F	P
Regression	88	26163123576	297308222	8321,23	0,000
Residual Error	1352	48305426	35729		
Total	1440	26211429002			

Lampiran 78. Normality Test dan ACF Residual *Window 1-7*
Model *Time Series Regression* dengan *Stepwise*.


a. *Window 1*





b. *Window 2*





c. *Window 3*





d. Window 4




e. Window 5



f. Window 6



g. Window 7



Lampiran 79. Variabel Terpilih dari Seleksi Input Menggunakan Metode *Stepwise* pada Model *Time Series Regression* dengan Menambahkan Lag Y_t .

===== Window 1=====									
'Yt1'	'D35'	'D36'	'D17'	'D16'	'D27'	'D15'	'D26'	'D9'	
'D10'	'D34'	'D12'	'D13'	'D43'	'D44'	'D24'	'D19'	'D42'	
'D46'	'D18'	'D21'	'D20'	'D8'	'J2'	'M27'	'D47'	'D48'	
'M15'	'J5'	'M16'	'D25'	'D22'	'D33'	'M17'	'S15'	'M26'	
'M24'	'M36'	'S27'	'S26'	'S13'	'D7'	'D39'	'M11'	'J3'	
'S25'	'D37'	'M10'	'M35'	'M31'	'D1'	'D41'	'D45'	'S24'	
'J4'	'M19'	'S34'	'M34'	'M18'	'M32'	'D28'	'S28'	'D14'	
'M20'	'M33'	'S33'	'D29'	'M14'	'S32'	'D32'	'M9'	'J1'	
===== Window 2=====									
'Yt1'	'D35'	'D36'	'D17'	'D15'	'D16'	'D27'	'D26'	'D9'	
'D10'	'D34'	'D12'	'D13'	'D43'	'D44'	'D24'	'D42'	'D46'	
'D19'	'D18'	'D21'	'D20'	'D8'	'J2'	'D47'	'M15'	'M27'	
'D48'	'J5'	'M16'	'M17'	'S27'	'D22'	'D25'	'D33'	'M24'	
'M26'	'S26'	'S15'	'M36'	'S25'	'D39'	'S13'	'D7'	'M11'	
'J3'	'D1'	'M35'	'M10'	'D41'	'D45'	'M31'	'J4'	'M18'	
'D37'	'D28'	'S28'	'S34'	'M34'	'M19'	'M20'	'M32'	'M33'	
'S33'	'S24'	'S32'	'D32'	'S16'	'D14'	'D29'	'M14'	'S14'	
'M9'	'S39'								

Lampiran 79. Variabel Terpilih dari Seleksi Input Menggunakan Metode *Stepwise* pada Model *Time Series Regression* dengan Menambahkan Lag Y_t (Lanjutan).

===== Window 3=====

'Yt1'	'D35'	'D36'	'D17'	'D16'	'D15'	'D27'	'D9'	'D10'
'D26'	'D34'	'D12'	'D13'	'D43'	'D44'	'D24'	'D42'	'D46'
'D19'	'D18'	'D21'	'D20'	'D8'	'M15'	'M27'	'J2'	'D47'
'D48'	'M16'	'M26'	'S26'	'M17'	'M24'	'S27'	'D33'	'D22'
'D25'	'S15'	'J5'	'S25'	'M36'	'S13'	'J3'	'D39'	'D7'
'M35'	'M11'	'M31'	'D1'	'D41'	'M18'	'M32'	'D37'	'D28'
'S28'	'M10'	'M33'	'M34'	'S34'	'J4'	'M19'	'S33'	'D45'
'M20'	'S24'	'S16'	'S32'	'D32'	'M9'	'D29'	'D14'	'M14'
'S14'	'S39'	'M23'						

===== Window 4=====

'Yt1'	'D35'	'D36'	'D17'	'D16'	'D15'	'D27'	'D9'	'D26'
'D10'	'D34'	'D12'	'D43'	'D13'	'D24'	'D44'	'D42'	'D46'
'D19'	'D18'	'D20'	'D21'	'D8'	'M15'	'M27'	'J2'	'D47'
'D48'	'M16'	'M26'	'M17'	'D22'	'S26'	'M24'	'S15'	'D25'
'D33'	'S27'	'M36'	'J5'	'S13'	'M35'	'D41'	'D1'	'M11'
'J3'	'S25'	'M31'	'D39'	'D7'	'M18'	'D28'	'D37'	'M32'
'M33'	'J4'	'M34'	'M10'	'D29'	'D14'	'M14'	'M20'	'M19'
'S34'	'S16'	'M9'	'S35'	'S20'	'J1'	'S33'	'M23'	'D31'
'D38'	'S32'							

===== Window 5=====

'Yt1'	'D35'	'D36'	'D17'	'D16'	'D15'	'D27'	'D26'	'D9'
'D10'	'D34'	'D12'	'D43'	'D13'	'D24'	'D44'	'D42'	'D46'
'D19'	'D18'	'D21'	'D20'	'D8'	'D47'	'J2'	'M15'	'M27'
'D48'	'J5'	'D22'	'M16'	'M17'	'S15'	'D25'	'D33'	'M26'
'M24'	'S27'	'M36'	'S26'	'D39'	'S13'	'M11'	'D41'	'D1'
'J3'	'M35'	'S25'	'M18'	'D7'	'J4'	'M10'	'D28'	'D37'
'D14'	'M31'	'D29'	'M32'	'M33'	'M20'	'M14'	'S16'	'M9'
'S35'	'S20'	'S34'	'M34'	'M19'	'D31'	'J1'	'M23'	'D38'
'S32'	'S33'							

Lampiran 79. Variabel Terpilih dari Seleksi Input Menggunakan Metode *Stepwise* pada Model *Time Series Regression* dengan Menambahkan Lag Y_t (Lanjutan).

===== Window 6=====								
'Yt1'	'D35'	'D36'	'D17'	'D16'	'D15'	'D27'	'D26'	'D9'
'D10'	'D34'	'D43'	'D12'	'D13'	'D24'	'D44'	'D42'	'D46'
'D19'	'D18'	'D21'	'D20'	'D8'	'D47'	'J2'	'M15'	'M27'
'D48'	'J5'	'D22'	'M16'	'D33'	'M17'	'D25'	'S15'	'M26'
'M24'	'M36'	'S26'	'S27'	'D39'	'S13'	'M11'	'D41'	'D1'
'J3'	'S25'	'M35'	'M18'	'D7'	'D37'	'D14'	'M31'	'D28'
'D29'	'M10'	'J4'	'M32'	'M20'	'M33'	'M14'	'S34'	'M34'
'S16'	'S20'	'M9'	'S35'	'J1'	'D31'	'M23'	'M19'	'D38'
'S32'								
===== Window 7=====								
'Yt1'	'D35'	'D36'	'D17'	'D15'	'D16'	'D27'	'D26'	'D9'
'D10'	'D34'	'D43'	'D12'	'D13'	'D24'	'D44'	'D42'	'D46'
'D19'	'D18'	'D21'	'D8'	'D20'	'D47'	'J2'	'M15'	'M27'
'D48'	'J5'	'D22'	'D33'	'M16'	'M17'	'S15'	'D25'	'M36'
'M26'	'M24'	'S26'	'S27'	'D39'	'S13'	'M11'	'D41'	'D1'
'J3'	'S25'	'M35'	'M18'	'D7'	'D37'	'D14'	'M31'	'J4'
'D28'	'D29'	'M10'	'M32'	'M20'	'M33'	'M14'	'S34'	'M34'
'S20'	'S16'	'M9'	'J1'	'D11'	'M19'	'D2'	'S35'	'D45'

Lampiran 80. Output Time Series Regression Window 1 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise.

The regression equation is

$$Y(t) = 0,991 Y_{t1} + 420 D35 + 201 D36 + 207 D17 + 202 D16 + 224 D27 + 222 D15 + 176 D26 + 159 D9 + 163 D10 + 119 D34 - 121 D12 - 106 D13 - 112 D43 - 93,5 D44 - 106 D24 + 113 D19 - 76,8 D42 - 72,4 D46 + 100 D18 + 92,0 D21 + 95,3 D20 + 83,4 D8 - 164 J2 - 190 M27 - 51,6 D47 - 48,7 D48 - 186 M15 + 91,3 J5 - 140 M16 + 54,6 D25 + 59,6 D22 + 36,7 D33 - 135 M17 - 122 S15 - 142 M26 + 114 M24 + 106 M36 - 106 S27 - 106 S26 - 91,3 S13 + 33,2 D7 + 33,3 D39 - 73,4 M11 - 61,0 J3 - 67,7 S25 + 24,8 D37 - 71,3 M10 + 68,9 M35 + 62,3 M31 - 22,9 D1 - 20,9 D41 - 19,6 D45 + 61,4 S24 + 54,9 J4 - 59,1 M19 + 66,1 S34 + 64,0 M34 - 57,0 M18 + 76,7 M32 + 29,7 D28 - 69,2 S28 + 25,6 D14 - 53,7 M20 + 59,2 M33 + 48,7 S33 + 15,4 D29 - 44,6 M14 + 60,4 S32 - 23,9 D32 - 40,6 M9 - 36,1 J1$$

Predictor	Coef	SE Coef	T	P
Noconstant				
Yt1	0,990839	0,000482	2055,26	0,000
D35	419,533	7,555	55,53	0,000
D36	201,471	7,610	26,48	0,000
D17	207,016	7,499	27,61	0,000
D16	201,705	7,478	26,97	0,000
D27	224,305	8,157	27,50	0,000
D15	222,196	8,072	27,53	0,000
D26	176,252	9,189	19,18	0,000
D9	158,883	7,472	21,26	0,000
D10	162,960	7,487	21,77	0,000
D34	118,652	8,157	14,55	0,000
D12	-120,770	7,010	-17,23	0,000
D13	-105,651	7,470	-14,14	0,000
D43	-111,879	7,102	-15,75	0,000
D44	-93,519	7,079	-13,21	0,000
D24	-106,055	9,203	-11,52	0,000
D19	113,426	7,529	15,07	0,000
D42	-76,843	7,121	-10,79	0,000
D46	-72,355	7,051	-10,26	0,000
D18	100,001	7,521	13,30	0,000
D21	92,007	7,050	13,05	0,000
D20	95,311	7,539	12,64	0,000
D8	83,405	6,979	11,95	0,000
J2	-163,94	16,65	-9,85	0,000
M27	-189,92	20,06	-9,47	0,000
D47	-51,583	7,035	-7,33	0,000

Lampiran 80. *Output Time Series Regression Window 1 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*

D48	-48,739	7,023	-6,94	0,000
M15	-185,85	20,06	-9,27	0,000
J5	91,30	18,77	4,86	0,000
M16	-140,33	19,82	-7,08	0,000
D25	54,633	8,298	6,58	0,000
D22	59,596	7,666	7,77	0,000
D33	36,742	8,157	4,50	0,000
M17	-135,01	19,82	-6,81	0,000
S15	-122,29	20,06	-6,10	0,000
M26	-142,08	20,51	-6,93	0,000
M24	114,28	20,51	5,57	0,000
M36	105,91	19,82	5,34	0,000
S27	-106,14	20,06	-5,29	0,000
S26	-106,33	20,50	-5,19	0,000
S13	-91,30	19,82	-4,61	0,000
D7	33,215	6,979	4,76	0,000
D39	33,273	7,141	4,66	0,000
M11	-73,42	18,54	-3,96	0,000
J3	-61,00	18,77	-3,25	0,001
S25	-67,69	20,13	-3,36	0,001
D37	24,831	7,150	3,47	0,001
M10	-71,29	19,82	-3,60	0,000
M35	68,94	19,82	3,48	0,001
M31	62,27	18,53	3,36	0,001
D1	-22,915	7,011	-3,27	0,001
D41	-20,881	7,131	-2,93	0,003
D45	-19,564	7,059	-2,77	0,006
S24	61,39	20,50	2,99	0,003
J4	54,89	18,36	2,99	0,003
M19	-59,09	19,82	-2,98	0,003
S34	66,11	20,06	3,30	0,001
M34	64,03	20,06	3,19	0,001
M18	-56,97	19,82	-2,87	0,004
M32	76,70	20,06	3,82	0,000
D28	29,702	7,553	3,93	0,000
S28	-69,23	19,82	-3,49	0,000
D14	25,575	7,459	3,43	0,001
M20	-53,70	19,82	-2,71	0,007
M33	59,21	20,06	2,95	0,003
S33	48,71	20,06	2,43	0,015
D29	15,365	7,068	2,17	0,030
M14	-44,62	19,82	-2,25	0,025
S32	60,44	20,06	3,01	0,003
D32	-23,858	8,166	-2,92	0,004

Lampiran 80. Output Time Series Regression Window 1 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).

M9	-40,61	19,82	-2,05	0,041	
J1	-36,06	18,08	-2,00	0,046	
S = 36,8960					
Analysis of Variance					
Source	DF	SS	MS	F	P
Regression	72	26370162927	366252263	269043,56	0,000
Residual Error	1368	1862275	1361		
Total	1440	26372025202			

Lampiran 81. Output Time Series Regression Window 2 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise.

The regression equation is					
Y(t) = 0,991 Yt1 + 419 D35 + 200 D36 + 205 D17 + 222 D15 + 207 D16 + 224 D27 + 177 D26 + 158 D9 + 161 D10 + 120 D34 - 121 D12 - 102 D13 - 114 D43 - 93,6 D44 - 108 D24 - 78,2 D42 - 72,9 D46 + 110 D19 + 104 D18 + 91,3 D21 + 97,3 D20 + 83,6 D8 - 164 J2 - 52,7 D47 - 186 M15 - 190 M27 - 47,4 D48 + 90,3 J5 - 145 M16 - 133 M17 - 121 S27 + 52,0 D22 + 52,9 D25 + 32,5 D33 + 116 M24 - 143 M26 - 114 S26 - 101 S15 + 107 M36 - 74,7 S25 + 40,6 D39 - 82,9 S13 + 31,8 D7 - 73,5 M11 - 59,0 J3 - 24,3 D1 + 68,9 M35 - 69,0 M10 - 19,5 D41 - 18,2 D45 + 62,2 M31 + 56,5 J4 - 61,0 M18 + 24,9 D37 + 31,6 D28 - 56,6 S28 + 61,3 S34 + 62,7 M34 - 55,8 M19 - 55,8 M20 + 76,4 M32 + 63,3 M33 + 50,5 S33 + 51,1 S24 + 66,3 S32 - 23,7 D32 - 43,2 S16 + 30,8 D14 + 16,9 D29 - 49,9 M14 - 44,0 S14 - 40,0 M9 - 36,5 S39					
Predictor	Coef	SE Coef	T	P	
Noconstant					
Yt1	0,990863	0,000478	2071,55	0,000	
D35	419,456	7,485	56,04	0,000	
D36	199,798	7,539	26,50	0,000	
D17	205,387	7,429	27,65	0,000	
D15	222,481	8,177	27,21	0,000	
D16	206,620	8,197	25,21	0,000	
D27	224,487	8,260	27,18	0,000	
D26	177,150	9,371	18,90	0,000	

Lampiran 81. *Output Time Series Regression Window 2 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*

D9	158,174	7,404	21,36	0,000
D10	160,608	7,419	21,65	0,000
D34	119,879	8,260	14,51	0,000
D12	-121,470	6,945	-17,49	0,000
D13	-102,146	7,539	-13,55	0,000
D43	-114,104	7,036	-16,22	0,000
D44	-93,575	7,013	-13,34	0,000
D24	-108,156	9,386	-11,52	0,000
D42	-78,220	7,055	-11,09	0,000
D46	-72,930	6,985	-10,44	0,000
D19	110,092	7,459	14,76	0,000
D18	103,897	7,451	13,94	0,000
D21	91,320	6,985	13,07	0,000
D20	97,289	7,469	13,03	0,000
D8	83,634	6,916	12,09	0,000
J2	-164,05	16,50	-9,94	0,000
D47	-52,659	6,970	-7,56	0,000
M15	-186,21	19,94	-9,34	0,000
M27	-190,19	19,95	-9,53	0,000
D48	-47,360	6,957	-6,81	0,000
J5	90,30	18,73	4,82	0,000
M16	-145,33	19,95	-7,29	0,000
M17	-133,47	19,64	-6,80	0,000
S27	-120,92	18,19	-6,65	0,000
D22	51,968	6,992	7,43	0,000
D25	52,921	8,413	6,29	0,000
D33	32,546	8,261	3,94	0,000
M24	116,30	20,44	5,69	0,000
M26	-143,07	20,44	-7,00	0,000
S26	-113,90	18,73	-6,08	0,000
S15	-101,47	18,19	-5,58	0,000
M36	107,48	19,64	5,47	0,000
S25	-74,70	18,28	-4,09	0,000
D39	40,633	7,683	5,29	0,000
S13	-82,86	17,91	-4,63	0,000
D7	31,832	6,916	4,60	0,000
M11	-73,51	18,37	-4,00	0,000
J3	-59,00	18,73	-3,15	0,002
D1	-24,298	6,947	-3,50	0,000
M35	68,93	19,64	3,51	0,000
M10	-69,02	19,63	-3,52	0,000

Lampiran 81. Output Time Series Regression Window 2 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).

D41	-19,517	7,065	-2,76	0,006
D45	-18,169	6,994	-2,60	0,009
M31	62,19	18,36	3,39	0,001
J4	56,50	18,28	3,09	0,002
M18	-60,95	19,64	-3,10	0,002
D37	24,911	7,084	3,52	0,000
D28	31,628	7,620	4,15	0,000
S28	-56,64	17,91	-3,16	0,002
S34	61,26	18,19	3,37	0,001
M34	62,72	19,95	3,14	0,002
M19	-55,84	19,64	-2,84	0,005
M20	-55,76	19,64	-2,84	0,005
M32	76,43	19,95	3,83	0,000
M33	63,32	19,95	3,17	0,002
S33	50,51	18,19	2,78	0,006
S24	51,05	18,73	2,73	0,006
S32	66,25	18,19	3,64	0,000
D32	-23,667	8,269	-2,86	0,004
S16	-43,19	18,19	-2,37	0,018
D14	30,762	8,178	3,76	0,000
D29	16,893	7,001	2,41	0,016
M14	-49,89	19,94	-2,50	0,012
S14	-43,98	18,19	-2,42	0,016
M9	-39,99	19,63	-2,04	0,042
S39	-36,45	17,91	-2,04	0,042

S = 36,5572

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	74	26270416531	355005629	265637,90	0,000
Residual Error	1366	1825559	1336		
Total	1440	26272242090			

Lampiran 82. *Output Time Series Regression Window 3 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise.*

The regression equation is					
Y(t) = 0,991 Yt1 + 421 D35 + 198 D36 + 203 D17 + 211 D16 + 222 D15 + 220 D27+ 157 D9 + 159 D10 + 177 D26 + 123 D34 - 120 D12 - 104 D13 - 113 D43 - 93,1 D44 - 108 D24 - 77,9 D42 - 72,6 D46 + 111 D19 + 106 D18 + 93,6 D21+ 96,3 D20 + 84,0 D8 - 187 M15 - 183 M27 - 156 J2 - 52,4 D47 - 46,4 D48 - 149 M16 - 143 M26 - 114 S26 - 132 M17 + 110 M24 - 117 S27 + 31,1 D33+ 50,2 D22 + 52,5 D25 - 101 S15 + 97,1 J5 - 74,0 S25 + 82,7 M36 - 80,7 S13 - 77,6 J3 + 40,0 D39 + 31,5 D7 + 78,5 M35 - 66,9 M11+ 69,0 M31 - 23,6 D1 - 21,8 D41 - 65,5 M18 + 80,3 M32 + 26,5 D37+ 34,2 D28 - 58,9 S28 - 58,9 M10 + 67,9 M33 + 67,7 M34 + 58,7 S34+ 61,9 J4 - 52,7 M19 + 52,2 S33 - 17,0 D45 - 49,5 M20 + 51,0 S24 - 46,9 S16 + 62,9 S32 - 20,0 D32 - 42,4 M9 + 17,1 D29 + 34,3 D14 - 61,4 M14 - 47,3 S14 - 35,6 S39 + 31,9 M23					
Predictor	Coef	SE Coef	T	P	
Noconstant					
Yt1	0,990807	0,000478	2073,32	0,000	
D35	421,193	7,544	55,83	0,000	
D36	197,553	7,598	26,00	0,000	
D17	202,914	7,489	27,10	0,000	
D16	210,583	8,302	25,37	0,000	
D15	222,198	8,282	26,83	0,000	
D27	220,311	8,364	26,34	0,000	
D9	156,719	7,464	21,00	0,000	
D10	158,813	7,478	21,24	0,000	
D26	177,395	9,273	19,13	0,000	
D34	122,625	8,364	14,66	0,000	
D12	-120,153	6,873	-17,48	0,000	
D13	-104,067	7,459	-13,95	0,000	
D43	-112,552	6,964	-16,16	0,000	
D44	-93,125	6,941	-13,42	0,000	
D24	-107,903	9,288	-11,62	0,000	
D42	-77,867	6,983	-11,15	0,000	
D46	-72,634	6,913	-10,51	0,000	
D19	110,994	7,518	14,76	0,000	
D18	105,724	7,510	14,08	0,000	
D21	93,570	6,910	13,54	0,000	
D20	96,306	7,528	12,79	0,000	
D8	83,965	6,844	12,27	0,000	
M15	-187,49	18,08	-10,37	0,000	
M27	-182,72	18,09	-10,10	0,000	

Lampiran 82. *Output Time Series Regression Window 3 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*

J2	-155,66	18,21	-8,55	0,000
D47	-52,392	6,897	-7,60	0,000
D48	-46,403	6,885	-6,74	0,000
M16	-148,54	18,08	-8,21	0,000
M26	-143,02	18,53	-7,72	0,000
S26	-113,91	18,53	-6,15	0,000
M17	-131,50	17,72	-7,42	0,000
M24	110,32	18,53	5,95	0,000
S27	-116,51	18,08	-6,44	0,000
D33	31,088	8,365	3,72	0,000
D22	50,189	6,918	7,26	0,000
D25	52,498	8,133	6,45	0,000
S15	-100,98	18,08	-5,59	0,000
J5	97,06	20,21	4,80	0,000
S25	-74,04	17,99	-4,12	0,000
M36	82,73	17,72	4,67	0,000
S13	-80,71	17,71	-4,56	0,000
J3	-77,63	20,21	-3,84	0,000
D39	40,032	7,603	5,27	0,000
D7	31,544	6,844	4,61	0,000
M35	78,46	17,72	4,43	0,000
M11	-66,88	16,27	-4,11	0,000
M31	69,02	16,26	4,25	0,000
D1	-23,565	6,876	-3,43	0,001
D41	-21,832	6,993	-3,12	0,002
M18	-65,52	17,72	-3,70	0,000
M32	80,33	18,09	4,44	0,000
D37	26,491	7,012	3,78	0,000
D28	34,161	7,536	4,53	0,000
S28	-58,94	17,71	-3,33	0,001
M10	-58,88	17,71	-3,32	0,001
M33	67,90	18,08	3,75	0,000
M34	67,73	18,08	3,75	0,000
S34	58,75	18,08	3,25	0,001
J4	61,93	19,73	3,14	0,002
M19	-52,73	17,72	-2,98	0,003
S33	52,20	18,08	2,89	0,004
D45	-17,040	6,921	-2,46	0,014
M20	-49,50	17,72	-2,79	0,005
S24	51,04	18,53	2,76	0,006
S16	-46,95	18,08	-2,60	0,010
S32	62,86	18,08	3,48	0,001
D32	-20,038	8,372	-2,39	0,017

Lampiran 82. *Output Time Series Regression Window 3 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*

M9	-42,43	17,71	-2,40	0,017
D29	17,114	6,926	2,47	0,014
D14	34,265	8,282	4,14	0,000
M14	-61,38	18,08	-3,39	0,001
S14	-47,28	18,08	-2,61	0,009
S39	-35,58	17,71	-2,01	0,045
M23	31,95	16,26	1,96	0,050

S = 36,1589

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	75	26006229664	346749729	265207,08	0,000
Residual Error	1365	1784694	1307		
Total	1440	26008014358			

Lampiran 83. *Output Time Series Regression Window 4 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise.*

The regression equation is

$$\begin{aligned}
 Y(t) = & 0,990 Y_{t1} + 416 D35 + 195 D36 + 212 D17 + 216 D16 + 228 \\
 & D15 + 225 D27 + 162 D9 + 181 D26 + 162 D10 + 129 D34 - \\
 & 114 D12 - 110 D43 - 98,0 D13 - 96,4 D24 - 88,9 D44 - 73,2 \\
 & D42 - 68,1 D46 + 115 D19 + 110 D18 + 98,7 D20 + 95,9 D21 \\
 & + 90,7 D8 - 190 M15 - 183 M27 - 150 J2 - 46,7 D47 - 41,6 \\
 & D48 - 150 M16 - 143 M26 - 137 M17 + 65,3 D22 - 116 S26 + \\
 & 103 M24 - 126 S15 + 54,1 D25 + 37,3 D33 - 113 S27 + 90,0 \\
 & M36 + 97,9 J5 - 93,8 S13 + 88,3 M35 - 17,5 D41 - 19,5 D1 \\
 & - 62,6 M11 - 84,1 J3 - 71,1 S25 + 55,1 M31 + 39,9 D39 + \\
 & 33,9 D7 - 66,2 M18 + 32,7 D28 + 32,6 D37 + 64,3 M32 + \\
 & 65,8 M33 + 65,0 J4 + 65,9 M34 - 57,7 M10 + 26,0 D29 \\
 & + 34,6 D14 - 57,9 M14 - 48,0 M20 - 53,1 M19 + 55,9 S34 - \\
 & 51,0 S16 - 43,5 M9 + 46,2 S35 + 44,7 S20 - 41,1 J1 + 40,4 \\
 & S33 + 35,9 M23 + 17,9 D31 + 15,0 D38 + 37,2 S32
 \end{aligned}$$

Lampiran 83. Output Time Series Regression Window 4 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).

Predictor	Coef	SE Coef	T	P
Noconstant				
Yt1	0,989682	0,000486	2034,75	0,000
D35	415,602	8,165	50,90	0,000
D36	195,095	7,584	25,72	0,000
D17	212,115	7,469	28,40	0,000
D16	216,099	8,088	26,72	0,000
D15	228,459	8,066	28,32	0,000
D27	224,736	8,154	27,56	0,000
D9	161,855	7,441	21,75	0,000
D26	181,350	8,984	20,19	0,000
D10	161,768	7,456	21,69	0,000
D34	128,528	8,154	15,76	0,000
D12	-114,149	6,855	-16,65	0,000
D43	-109,603	6,951	-15,77	0,000
D13	-98,036	7,302	-13,43	0,000
D24	-96,406	8,148	-11,83	0,000
D44	-88,925	6,927	-12,84	0,000
D42	-73,247	6,971	-10,51	0,000
D46	-68,109	6,898	-9,87	0,000
D19	115,189	7,500	15,36	0,000
D18	110,231	7,491	14,71	0,000
D20	98,726	8,148	12,12	0,000
D21	95,851	6,896	13,90	0,000
D8	90,702	6,824	13,29	0,000
M15	-189,98	17,92	-10,60	0,000
M27	-183,17	17,93	-10,22	0,000
J2	-150,44	18,15	-8,29	0,000
D47	-46,702	6,882	-6,79	0,000
D48	-41,639	6,869	-6,06	0,000
M16	-150,28	17,92	-8,39	0,000
M26	-143,00	18,32	-7,80	0,000
M17	-136,89	17,65	-7,76	0,000
D22	65,275	7,362	8,87	0,000
S26	-115,50	20,01	-5,77	0,000
M24	102,81	17,93	5,74	0,000
S15	-125,89	19,65	-6,41	0,000
D25	54,149	7,937	6,82	0,000
D33	37,264	8,156	4,57	0,000
S27	-113,34	19,65	-5,77	0,000
M36	89,99	17,64	5,10	0,000
J5	97,93	20,01	4,89	0,000
S13	-93,81	19,34	-4,85	0,000

Lampiran 83. *Output Time Series Regression Window 4 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*

M35	88,33	17,92	4,93	0,000	
D41	-17,476	6,982	-2,50	0,012	
D1	-19,475	6,857	-2,84	0,005	
M11	-62,63	16,21	-3,86	0,000	
J3	-84,13	19,65	-4,28	0,000	
S25	-71,13	19,57	-3,63	0,000	
M31	55,11	17,65	3,12	0,002	
D39	39,926	6,992	5,71	0,000	
D7	33,900	6,825	4,97	0,000	
M18	-66,17	17,65	-3,75	0,000	
D28	32,732	6,915	4,73	0,000	
D37	32,583	7,001	4,65	0,000	
M32	64,29	16,20	3,97	0,000	
M33	65,75	17,93	3,67	0,000	
J4	65,02	19,57	3,32	0,001	
M34	65,93	17,92	3,68	0,000	
M10	-57,66	17,64	-3,27	0,001	
D29	26,047	6,913	3,77	0,000	
D14	34,625	7,428	4,66	0,000	
M14	-57,90	17,64	-3,28	0,001	
M20	-48,02	17,93	-2,68	0,007	
M19	-53,06	17,65	-3,01	0,003	
S34	55,94	19,65	2,85	0,004	
S16	-50,99	19,65	-2,60	0,010	
M9	-43,48	17,64	-2,46	0,014	
S35	46,21	19,65	2,35	0,019	
S20	44,66	19,65	2,27	0,023	
J1	-41,10	19,34	-2,12	0,034	
S33	40,41	19,65	2,06	0,040	
M23	35,93	16,20	2,22	0,027	
D31	17,860	7,527	2,37	0,018	
D38	14,963	6,998	2,14	0,033	
S32	37,18	18,11	2,05	0,040	
S = 36,0120					
Analysis of Variance					
Source	DF	SS	MS	F	P
Regression	74	26004585531	351413318	270971,34	0,000
Residual Error	1366	1771518	1297		
Total	1440	26006357049			

Lampiran 84. Output Time Series Regression Window 5 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise.

The regression equation is

$$Y(t) = 0,990 Y_{t1} + 417 D35 + 190 D36 + 211 D17 + 216 D16 + 230 D15 + 225 D27 + 180 D26 + 163 D9 + 162 D10 + 133 D34 - 114 D12 - 111 D43 - 96,8 D13 - 95,0 D24 - 87,2 D44 - 73,3 D42 - 69,9 D46 + 113 D19 + 111 D18 + 98,2 D21 + 98,3 D20 + 93,1 D8 - 47,6 D47 - 150 J2 - 194 M15 - 187 M27 - 41,3 D48 + 99,1 J5 + 65,5 D22 - 142 M16 - 132 M17 - 127 S15 + 52,3 D25 + 38,2 D33 - 139 M26 + 97,8 M24 - 113 S27 + 110 M36 - 114 S26 + 43,4 D39 - 94,9 S13 - 75,7 M11 - 19,6 D41 - 20,7 D1 - 85,3 J3 + 85,6 M35 - 69,1 S25 - 72,4 M18 + 33,7 D7 + 67,1 J4 - 66,8 M10 + 32,8 D28 + 33,9 D37 + 36,3 D14 + 49,6 M31 + 25,5 D29 + 59,4 M32 + 65,5 M33 - 52,8 M20 - 52,0 M14 - 50,9 S16 - 45,4 M9 + 45,5 S35 + 45,3 S20 + 51,7 S34 + 51,1 M34 - 43,8 M19 + 18,2 D31 - 41,1 J1 + 38,7 M23 + 15,0 D38 + 37,4 S32 + 39,7 S33$$

Predictor	Coef	SE Coef	T	P
Noconstant				
Yt1	0,989629	0,000487	2032,26	0,000
D35	416,569	8,047	51,77	0,000
D36	190,406	7,502	25,38	0,000
D17	210,535	7,385	28,51	0,000
D16	216,244	7,967	27,14	0,000
D15	229,557	7,945	28,89	0,000
D27	225,096	8,034	28,02	0,000
D26	180,433	8,805	20,49	0,000
D9	162,940	7,356	22,15	0,000
D10	161,735	7,372	21,94	0,000
D34	132,971	8,035	16,55	0,000
D12	-113,981	6,902	-16,51	0,000
D43	-111,076	7,000	-15,87	0,000
D13	-96,774	7,353	-13,16	0,000
D24	-95,022	8,029	-11,83	0,000
D44	-87,158	6,975	-12,50	0,000
D42	-73,276	7,019	-10,44	0,000
D46	-69,936	6,947	-10,07	0,000
D19	113,174	7,417	15,26	0,000
D18	111,166	7,407	15,01	0,000
D21	98,229	6,947	14,14	0,000
D20	98,305	8,028	12,25	0,000
D8	93,113	6,871	13,55	0,000
D47	-47,555	6,930	-6,86	0,000
J2	-150,20	18,28	-8,22	0,000

Lampiran 84. *Output Time Series Regression Window 5 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*

M15	-193,89	19,72	-9,83	0,000
M27	-187,28	19,72	-9,50	0,000
D48	-41,279	6,917	-5,97	0,000
J5	99,08	20,05	4,94	0,000
D22	65,541	7,417	8,84	0,000
M16	-141,52	19,72	-7,18	0,000
M17	-132,15	19,49	-6,78	0,000
S15	-126,79	19,72	-6,43	0,000
D25	52,317	7,996	6,54	0,000
D33	38,188	8,036	4,75	0,000
M26	-139,30	20,06	-6,95	0,000
M24	97,77	19,72	4,96	0,000
S27	-113,48	19,72	-5,76	0,000
M36	109,55	19,49	5,62	0,000
S26	-114,36	20,05	-5,70	0,000
D39	43,394	7,040	6,16	0,000
S13	-94,86	19,48	-4,87	0,000
M11	-75,71	18,23	-4,15	0,000
D41	-19,568	7,031	-2,78	0,005
D1	-20,727	6,904	-3,00	0,003
J3	-85,28	19,72	-4,33	0,000
M35	85,61	19,72	4,34	0,000
S25	-69,08	19,72	-3,50	0,000
M18	-72,38	19,49	-3,71	0,000
D7	33,678	6,872	4,90	0,000
J4	67,08	19,72	3,40	0,001
M10	-66,81	19,48	-3,43	0,001
D28	32,799	6,967	4,71	0,000
D37	33,875	7,049	4,81	0,000
D14	36,268	7,343	4,94	0,000
M31	49,57	19,49	2,54	0,011
D29	25,506	6,965	3,66	0,000
M32	59,40	18,22	3,26	0,001
M33	65,47	19,72	3,32	0,001
M20	-52,75	19,72	-2,67	0,008
M14	-51,95	19,48	-2,67	0,008
S16	-50,93	19,72	-2,58	0,010
M9	-45,44	19,48	-2,33	0,020
S35	45,47	19,72	2,31	0,021
S20	45,30	19,72	2,30	0,022
S34	51,72	19,72	2,62	0,009
M34	51,06	19,72	2,59	0,010
M19	-43,75	19,49	-2,24	0,025

Lampiran 84. Output Time Series Regression Window 5 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).

D31	18,159	7,444	2,44	0,015	
J1	-41,11	19,48	-2,11	0,035	
M23	38,70	18,22	2,12	0,034	
D38	15,046	7,046	2,14	0,033	
S32	37,39	18,25	2,05	0,041	
S33	39,70	19,72	2,01	0,044	
S = 36,2760					
Analysis of Variance					
Source	DF	SS	MS	F	P
Regression	74	26189115318	353906964	268937,30	0,000
Residual Error	1366	1797582	1316		
Total	1440	26190912901			

Lampiran 85. Output Time Series Regression Window 6 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise.

The regression equation is				
Y(t) = 0,990 Yt1 + 420 D35 + 188 D36 + 209 D17 + 213 D16 + 228 D15 + 226 D27 + 183 D26 + 163 D9 + 161 D10 + 125 D34 - 112 D43 - 110 D12 - 95,3 D13 - 98,0 D24 - 87,5 D44 - 73,4 D42 - 68,6 D46 + 110 D19 + 114 D18 + 99,9 D21 + 97,3 D20 + 93,6 D8 - 48,0 D47 - 150 J2 - 192 M15 - 188 M27 - 39,7 D48 + 96,6 J5 + 65,1 D22 - 138 M16 + 49,7 D33 - 131 M17 + 54,5 D25 - 125 S15 - 142 M26 + 101 M24 + 113 M36 - 117 S26 - 114 S27 + 44,7 D39 - 96,0 S13 - 75,4 M11 - 18,9 D41 - 19,5 D1 - 82,0 J3 - 71,0 S25 + 82,4 M35 - 74,7 M18 + 34,1 D7 + 33,8 D37 + 37,1 D14 + 50,4 M31 + 29,6 D28 + 28,1 D29 - 65,9 M10 + 65,2 J4 + 59,7 M32 - 51,5 M20 + 54,2 M33 - 52,6 M14 + 59,6 S34 + 58,9 M34 - 47,4 S16 + 46,6 S20 - 45,2 M9 + 42,3 S35 - 40,4 J1 + 17,6 D31 + 39,0 M23 - 40,2 M19 + 14,6 D38 + 37,7 S32				
Predictor	Coef	SE Coef	T	P
Noconstant				
Yt1	0,989552	0,000489	2025,01	0,000
D35	420,035	8,082	51,97	0,000
D36	187,761	7,535	24,92	0,000
D17	209,429	7,418	28,23	0,000

Lampiran 85. *Output Time Series Regression Window 6 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*

D16	212,950	8,004	26,61	0,000
D15	228,130	7,982	28,58	0,000
D27	226,119	8,070	28,02	0,000
D26	183,200	8,845	20,71	0,000
D9	162,940	7,390	22,05	0,000
D10	161,095	7,406	21,75	0,000
D34	125,364	8,072	15,53	0,000
D43	-111,637	7,030	-15,88	0,000
D12	-110,084	6,933	-15,88	0,000
D13	-95,317	7,387	-12,90	0,000
D24	-97,981	8,065	-12,15	0,000
D44	-87,525	7,005	-12,49	0,000
D42	-73,416	7,050	-10,41	0,000
D46	-68,597	6,977	-9,83	0,000
D19	109,848	7,450	14,74	0,000
D18	113,719	7,441	15,28	0,000
D21	99,944	6,977	14,32	0,000
D20	97,287	8,064	12,06	0,000
D8	93,611	6,903	13,56	0,000
D47	-47,987	6,961	-6,89	0,000
J2	-149,84	18,36	-8,16	0,000
M15	-192,21	19,81	-9,70	0,000
M27	-188,04	19,81	-9,49	0,000
D48	-39,715	6,948	-5,72	0,000
J5	96,64	20,14	4,80	0,000
D22	65,135	7,450	8,74	0,000
M16	-137,97	19,81	-6,96	0,000
D33	49,695	7,466	6,66	0,000
M17	-130,78	19,57	-6,68	0,000
D25	54,531	8,031	6,79	0,000
S15	-125,08	19,81	-6,31	0,000
M26	-141,79	20,15	-7,04	0,000
M24	101,00	19,81	5,10	0,000
M36	112,51	19,57	5,75	0,000
S26	-116,82	20,14	-5,80	0,000
S27	-114,19	19,81	-5,76	0,000
D39	44,699	7,071	6,32	0,000
S13	-96,02	19,57	-4,91	0,000
M11	-75,42	18,31	-4,12	0,000
D41	-18,857	7,061	-2,67	0,008
D1	-19,467	6,936	-2,81	0,005
J3	-81,98	19,81	-4,14	0,000

Lampiran 85. Output Time Series Regression Window 6 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode *Stepwise* (Lanjutan).

S25	-70,97	19,81	-3,58	0,000
M35	82,43	19,81	4,16	0,000
M18	-74,67	19,58	-3,81	0,000
D7	34,130	6,904	4,94	0,000
D37	33,757	7,080	4,77	0,000
D14	37,141	7,376	5,04	0,000
M31	50,39	19,58	2,57	0,010
D28	29,581	6,998	4,23	0,000
D29	28,125	6,995	4,02	0,000
M10	-65,88	19,57	-3,37	0,001
J4	65,19	19,81	3,29	0,001
M32	59,67	18,30	3,26	0,001
M20	-51,47	19,81	-2,60	0,009
M33	54,24	19,58	2,77	0,006
M14	-52,57	19,57	-2,69	0,007
S34	59,64	19,81	3,01	0,003
M34	58,94	19,81	2,98	0,003
S16	-47,35	19,81	-2,39	0,017
S20	46,63	19,81	2,35	0,019
M9	-45,16	19,57	-2,31	0,021
S35	42,33	19,81	2,14	0,033
J1	-40,35	19,57	-2,06	0,039
D31	17,608	7,477	2,36	0,019
M23	38,97	18,30	2,13	0,033
M19	-40,16	19,58	-2,05	0,040
D38	14,572	7,077	2,06	0,040
S32	37,70	18,33	2,06	0,040

S = 36,4404

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	73	26208986346	359027210	270371,16	0,000
Residual Error	1367	1815246	1328		
Total	1440	26210801592			

Lampiran 86. Output Time Series Regression Window 7 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise.

The regression equation is

$$Y(t) = 0,991 Y_{t1} + 416 D35 + 176 D36 + 203 D17 + 225 D15 + 207 D16 + 218 D27 + 175 D26 + 157 D9 + 154 D10 + 120 D34 - 119 D43 - 116 D12 - 99,9 D13 - 103 D24 - 92,8 D44 - 81,2 D42 - 75,5 D46 + 105 D19 + 108 D18 + 93,1 D21 + 89,8 D8 + 89,0 D20 - 55,0 D47 - 157 J2 - 194 M15 - 185 M27 - 45,1 D48 + 97,8 J5 + 60,0 D22 + 44,2 D33 - 137 M16 - 129 M17 - 127 S15 + 46,1 D25 + 118 M36 - 139 M26 + 100 M24 - 115 S26 - 112 S27 + 36,6 D39 - 97,4 S13 - 63,1 M11 - 25,7 D41 - 26,0 D1 - 84,0 J3 - 68,9 S25 + 80,9 M35 - 73,9 M18 + 29,0 D7 + 27,0 D37 + 32,6 D14 + 62,7 M31 + 67,2 J4 + 22,3 D28 + 22,3 D29 - 64,8 M10 + 54,3 M32 - 48,4 M20 + 54,3 M33 - 53,2 M14 + 58,9 S34 + 58,9 M34 + 48,7 S20 - 46,7 S16 - 44,3 M9 - 42,3 J1 - 18,0 D11 - 40,4 M19 - 15,3 D2 + 40,1 S35 - 13,8 D45$$

Predictor	Coef	SE Coef	T	P
Noconstant				
Yt1	0,991075	0,000495	2003,52	0,000
D35	415,779	8,112	51,25	0,000
D36	175,675	7,566	23,22	0,000
D17	202,560	7,445	27,21	0,000
D15	224,709	8,010	28,05	0,000
D16	206,639	8,032	25,73	0,000
D27	217,859	8,100	26,90	0,000
D26	175,495	8,876	19,77	0,000
D9	156,580	7,417	21,11	0,000
D10	154,409	7,433	20,77	0,000
D34	119,861	8,101	14,79	0,000
D43	-118,701	7,058	-16,82	0,000
D12	-116,234	6,958	-16,70	0,000
D13	-99,922	7,413	-13,48	0,000
D24	-102,742	8,095	-12,69	0,000
D44	-92,811	7,033	-13,20	0,000
D42	-81,160	7,079	-11,47	0,000
D46	-75,467	7,005	-10,77	0,000
D19	104,840	7,478	14,02	0,000
D18	107,758	7,468	14,43	0,000
D21	93,055	7,004	13,29	0,000
D8	89,819	6,928	12,96	0,000
D20	88,997	8,094	11,00	0,000
D47	-55,027	6,988	-7,87	0,000
J2	-156,91	18,42	-8,52	0,000

Lampiran 86. *Output Time Series Regression Window 7 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*



M15	-193,87	19,87	-9,76	0,000
M27	-185,15	19,87	-9,32	0,000
D48	-45,085	6,974	-6,46	0,000
J5	97,81	20,20	4,84	0,000
D22	59,956	7,478	8,02	0,000
D33	44,205	7,494	5,90	0,000
M16	-136,74	19,87	-6,88	0,000
M17	-129,05	19,63	-6,57	0,000
S15	-127,26	19,87	-6,41	0,000
D25	46,119	8,061	5,72	0,000
M36	118,15	19,63	6,02	0,000
M26	-139,46	20,21	-6,90	0,000
M24	100,38	19,87	5,05	0,000
S26	-115,36	20,20	-5,71	0,000
S27	-112,22	19,87	-5,65	0,000
D39	36,592	7,100	5,15	0,000
S13	-97,40	19,63	-4,96	0,000
M11	-63,14	19,63	-3,22	0,001
D41	-25,725	7,090	-3,63	0,000
D1	-26,021	6,962	-3,74	0,000
J3	-83,99	19,87	-4,23	0,000
S25	-68,90	19,87	-3,47	0,001
M35	80,93	19,87	4,07	0,000
M18	-73,92	19,63	-3,76	0,000
D7	28,967	6,929	4,18	0,000
D37	26,984	7,109	3,80	0,000
D14	32,602	7,402	4,40	0,000
M31	62,65	18,36	3,41	0,001
J4	67,18	19,87	3,38	0,001
D28	22,344	7,025	3,18	0,002
D29	22,250	7,022	3,17	0,002
M10	-64,84	19,63	-3,30	0,001
M32	54,28	18,36	2,96	0,003
M20	-48,45	19,87	-2,44	0,015
M33	54,31	19,64	2,77	0,006
M14	-53,19	19,63	-2,71	0,007
S34	58,89	19,87	2,96	0,003
M34	58,92	19,87	2,97	0,003
S20	48,66	19,87	2,45	0,014
S16	-46,74	19,87	-2,35	0,019
M9	-44,32	19,63	-2,26	0,024
J1	-42,28	19,63	-2,15	0,031
D11	-18,011	7,449	-2,42	0,016
M19	-40,37	19,64	-2,06	0,040

Lampiran 86. *Output Time Series Regression Window 7 yang Menyertakan Lag dengan Seleksi Input Menggunakan Metode Stepwise (Lanjutan).*



D2	-15,313	6,954	-2,20	0,028	
S35	40,11	19,87	2,02	0,044	
D45	-13,837	7,012	-1,97	0,049	
S = 36,5500					
Analysis of Variance					
Source	DF	SS	MS	F	P
Regression	72	26209601488	364022243	272491,81	0,000
Residual Error	1368	1827513	1336		
Total	1440	26211429002			

Lampiran 87. *Normality Test dan ACF Residual Window 1-7 Model Time Series Regression yang Menyertakan Lag Y_t dengan Stepwise.*


a. Window 1




b. Window 2




c. Window 3




d. Window 4




e. Window 5



f. *Window 6*



g. *Window 7*



Lampiran 88. *Syntax Double Seasonal ARIMA pada Window 1 dengan Seleksi Input Stepwise.*

```

data listrik;
input y;
datalines;
3988.1
3945.2
3959.5
:
4091.0
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate
  p=(1,15,334,335,336,337,338,340,351,384,385) (0) (0) q=(1)
(48) (336) noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanARIMA_Stepwise_1.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```

Lampiran 89. *Output Double Seasonal ARIMA pada Window 1 dengan Seleksi Input Stepwise.*

Maximum Likelihood Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	-0.20235	0.25038	-0.81	0.4190	1				
MA2,1	0.85181	0.02813	30.28	<.0001	48				
MA3,1	0.99992	651.67643	0.00	0.9988	336				
AR1,1	-0.24208	0.24605	-0.98	0.3252	1				
AR1,2	-0.05448	0.02702	-2.02	0.0437	15				
AR1,3	-0.03937	0.03269	-1.20	0.2285	334				
AR1,4	0.02272	0.03729	0.61	0.5423	335				
AR1,5	0.25064	0.10665	2.35	0.0188	336				
AR1,6	-0.0023877	0.07580	-0.03	0.9749	337				
AR1,7	-0.0030005	0.03301	-0.09	0.9276	338				
AR1,8	-0.08466	0.03079	-2.75	0.0060	340				
AR1,9	-0.0037090	0.03178	-0.12	0.9071	351				
AR1,10	-0.01883	0.03180	-0.59	0.5537	384				
AR1,11	-0.0041955	0.03173	-0.13	0.8948	385				
Variance Estimate			1720.851						
Std Error Estimate			41.48314						
AIC			11311.47						
SBC			11380.93						
Number of Residuals			1055						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.022	0.025	0.047	-0.010	0.066	0.071
12	.	0	.	-0.070	0.042	0.024	0.022	0.087	-0.047
18	41.22	4	<.0001	-0.008	0.065	-0.009	-0.008	-0.036	-0.050
24	62.26	10	<.0001	-0.010	-0.092	-0.045	-0.035	-0.072	0.050
30	72.53	16	<.0001	0.013	0.038	0.023	0.000	-0.006	0.085
36	80.71	22	<.0001	-0.041	-0.006	0.002	-0.052	0.042	0.036
42	95.67	28	<.0001	-0.056	-0.002	-0.042	0.003	0.032	-0.087
48	103.53	34	<.0001	0.003	-0.023	-0.033	-0.070	0.025	0.001

Lampiran 90. *Syntax Double Seasonal ARIMA pada Window 2 dengan Seleksi Input Stepwise.*

```

data listrik;
input y;
datalines;
4042.9
3980.0
3931.1
3931.3
3890.2
:
3720.5
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate
p=(1,5,288,289,290,334,335,336,337,338,340,384,385) (0)
(0) q=(1) (48) (336) noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanARIMA_Stepwise_2.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```

Lampiran 91. *Output Double Seasonal ARIMA pada Window 2 dengan Seleksi Input Stepwise.*

Maximum Likelihood Estimation									
Parameter			Estimate	Standard Error	t Value	Approx Pr > t	Lag		
MA1,1			0.18535	0.22724	0.82	0.4147	1		
MA2,1			0.84303	0.02866	29.42	<.0001	48		
MA3,1			0.99916	52.02583	0.02	0.9847	336		
AR1,1			0.12110	0.22830	0.53	0.5958	1		
AR1,2			0.04888	0.02381	2.05	0.0401	5		
AR1,3			0.03267	0.02797	1.17	0.2429	288		
AR1,4			-0.04419	0.02852	-1.55	0.1213	289		
AR1,5			0.01513	0.02762	0.55	0.5838	290		
AR1,6			-0.08574	0.02714	-3.16	0.0016	334		
AR1,7			0.01598	0.03579	0.45	0.6552	335		
AR1,8			-0.03311	0.06725	-0.49	0.6224	336		
AR1,9			-0.0022622	0.03050	-0.07	0.9409	337		
AR1,10			-0.04214	0.02703	-1.56	0.1190	338		
AR1,11			-0.06437	0.02725	-2.36	0.0182	340		
AR1,12			-0.01051	0.03014	-0.35	0.7274	384		
AR1,13			-0.01057	0.02823	-0.37	0.7081	385		
Variance Estimate					1433.744				
Std Error Estimate					37.86482				
AIC					11253.23				
SBC					11332.61				
Number of Residuals					1055				
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	0.002	0.026	0.036	-0.012	-0.005	0.070
12	.	0	.	-0.050	0.034	0.024	0.019	0.070	-0.054
18	29.00	2	<.0001	-0.019	0.068	-0.034	-0.011	-0.018	-0.035
24	47.70	8	<.0001	-0.028	-0.079	-0.049	-0.054	-0.061	0.037
30	54.49	14	<.0001	0.011	0.044	0.003	0.013	0.008	0.063
36	59.61	20	<.0001	-0.042	0.020	-0.009	-0.014	0.020	0.043
42	69.56	26	<.0001	-0.036	-0.012	-0.034	-0.001	0.028	-0.076
48	75.44	32	<.0001	0.001	-0.022	-0.031	-0.055	0.029	0.001

Lampiran 92. *Syntax Double Seasonal ARIMA pada Window 3 dengan Seleksi Input Stepwise.*

```

data listrik;
input y;
datalines;
4013.4
4023.0
3930.0
3914.0
3929.2
:
3580.9
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate
p=(1,5,288,289,290,334,335,336,337,338,340,384,385) (0)
(0) q=(1) (48) (336) noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanARIMA_Stepwise_3.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```


Lampiran 93. *Output Double Seasonal ARIMA pada Window 3 dengan Seleksi Input Stepwise.*

Maximum Likelihood Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.27365	0.22120	1.24	0.2160	1				
MA2,1	0.77097	0.02622	29.40	<.0001	48				
MA3,1	0.99901	44.15160	0.02	0.9819	336				
AR1,1	0.23048	0.22209	1.04	0.2994	1				
AR1,2	0.06123	0.02441	2.51	0.0121	5				
AR1,3	0.06683	0.02823	2.37	0.0179	288				
AR1,4	-0.05794	0.03220	-1.80	0.0719	289				
AR1,5	0.0018403	0.02783	0.07	0.9473	290				
AR1,6	-0.07635	0.02725	-2.80	0.0051	334				
AR1,7	0.01876	0.03500	0.54	0.5919	335				
AR1,8	-0.0096842	0.06844	-0.14	0.8875	336				
AR1,9	-0.0091358	0.03265	-0.28	0.7796	337				
AR1,10	-0.03339	0.02736	-1.22	0.2223	338				
AR1,11	-0.06489	0.02779	-2.34	0.0195	340				
AR1,12	0.0050504	0.02986	0.17	0.8657	384				
AR1,13	-0.01172	0.02771	-0.42	0.6723	385				
Variance Estimate				1478.577					
Std Error Estimate				38.45227					
AIC				11247.91					
SBC				11327.29					
Number of Residuals				1055					
Autocorrelation Check of Residuals									
To Lag	Chi-Squar	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.007	0.036	0.024	-0.012	-0.024	0.075
12	.	0	.	-0.064	0.032	0.031	0.019	0.058	-0.047
18	27.89	2	<.0001	-0.015	0.059	-0.029	-0.014	-0.010	-0.034
24	43.60	8	<.0001	-0.034	-0.068	-0.050	-0.053	-0.049	0.031
30	52.73	14	<.0001	-0.006	0.051	0.021	0.010	0.012	0.071
36	56.06	20	<.0001	-0.036	0.008	-0.020	-0.015	0.023	0.023
42	66.70	26	<.0001	-0.025	0.005	-0.038	0.003	0.029	-0.082
48	74.90	32	<.0001	-0.009	-0.021	-0.022	-0.063	0.046	-0.017

Lampiran 94. *Syntax Double Seasonal ARIMA pada Window 4 dengan Seleksi Input Stepwise.*

```

data listrik;
input y;
datalines;
3833.5
3783.4
3737.7
3695.2
3659.6
:
3938.2
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate p=(1,15,334,335,336,337,338,340,352,384,385)
(0) (0) q=(1) (48) (336) noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanARIMA_Stepwise_4.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```

Lampiran 95. *Output Double Seasonal ARIMA pada Window 4 dengan Seleksi Input Stepwise.*

Maximum Likelihood Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	-0.14475	0.32015	-0.45	0.6512	1				
MA2,1	0.77780	0.02654	29.30	<.0001	48				
MA3,1	0.99998	3954.6	0.00	0.9998	336				
AR1,1	-0.20013	0.31824	-0.63	0.5294	1				
AR1,2	-0.0016148	0.02425	-0.07	0.9469	15				
AR1,3	-0.07455	0.02902	-2.57	0.0102	334				
AR1,4	-0.0028348	0.03917	-0.07	0.9423	335				
AR1,5	0.03890	0.06435	0.60	0.5455	336				
AR1,6	-0.0065231	0.03281	-0.20	0.8424	337				
AR1,7	-0.03397	0.02841	-1.20	0.2317	338				
AR1,8	-0.04960	0.02777	-1.79	0.0740	340				
AR1,9	-0.0013547	0.02715	-0.05	0.9602	352				
AR1,10	0.0007219	0.02906	0.02	0.9802	384				
AR1,11	-0.0010280	0.02805	-0.04	0.9708	385				
Variance Estimate			1505.644						
Std Error Estimate			38.80263						
AIC			11242.74						
SBC			11312.19						
Number of Residuals			1055						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	0.013	0.037	0.040	0.026	0.063	0.078
12	.	0	.	-0.044	0.009	0.029	0.035	0.068	-0.052
18	36.64	4	<.0001	-0.020	0.060	-0.022	-0.014	-0.029	-0.060
24	53.31	10	<.0001	-0.030	-0.070	-0.053	-0.064	-0.051	0.013
30	63.23	16	<.0001	-0.005	0.043	0.008	0.017	-0.004	0.083
36	66.47	22	<.0001	-0.025	0.005	-0.001	-0.031	0.019	0.031
42	77.50	28	<.0001	-0.035	0.007	-0.040	-0.004	0.024	-0.081
48	91.67	34	<.0001	-0.023	-0.014	-0.031	-0.068	0.060	-0.054

Lampiran 95. *Syntax Double Seasonal ARIMA pada Window 5 dengan Seleksi Input Stepwise.*

```

data listrik;
input y;
datalines;
3737.6
3698.3
3667.4
3619.4
3597.9
:
4048.4
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate
p=(1,15,288,289,290,333,335,336,337,338,351,384,385) (0)
(0) q=(1) (48) (336) noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanARIMA_Stepwise_5.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```

Lampiran 97. *Output Double Seasonal ARIMA pada Window 5 dengan Seleksi Input Stepwise.*

Maximum Likelihood Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	-0.41843	0.27046	-1.55	0.1218	1				
MA2,1	0.72217	0.02670	27.05	<.0001	48				
MA3,1	0.99938	83.43174	0.01	0.9904	336				
AR1,1	-0.48755	0.25995	-1.88	0.0607	1				
AR1,2	0.0035688	0.02432	0.15	0.8833	15				
AR1,3	0.10601	0.03024	3.51	0.0005	288				
AR1,4	0.01447	0.04188	0.35	0.7298	289				
AR1,5	-0.02582	0.02860	-0.90	0.3666	290				
AR1,6	0.0019039	0.02745	0.07	0.9447	333				
AR1,7	-0.0023845	0.03078	-0.08	0.9382	335				
AR1,8	0.03942	0.06842	0.58	0.5645	336				
AR1,9	-0.01964	0.04276	-0.46	0.6461	337				
AR1,10	-0.03084	0.02820	-1.09	0.2741	338				
AR1,11	0.0016719	0.02765	0.06	0.9518	351				
AR1,12	0.04787	0.03175	1.51	0.1316	384				
AR1,13	0.0089121	0.03186	0.28	0.7797	385				
Variance Estimate			1543.674						
Std Error Estimate			39.28962						
AIC			11254.39						
SBC			11333.77						
Number of Residuals			1055						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	0.020	0.046	0.053	0.043	0.058	0.075
12	.	0	.	-0.040	0.010	0.025	0.047	0.058	-0.047
18	37.39	2	<.0001	-0.025	0.055	-0.024	-0.019	-0.037	-0.054
24	57.66	8	<.0001	-0.048	-0.079	-0.049	-0.068	-0.053	0.019
30	68.12	14	<.0001	-0.001	0.049	0.015	0.020	0.014	0.080
36	71.72	20	<.0001	-0.012	0.017	-0.000	-0.045	0.020	0.022
42	80.14	26	<.0001	-0.040	0.002	-0.027	-0.001	0.010	-0.073
48	92.62	32	<.0001	-0.032	-0.005	-0.043	-0.075	0.025	-0.046

Lampiran 98. *Syntax Double Seasonal ARIMA pada Window 6 dengan Seleksi Input Stepwise.*

```

data listrik;
input y;
datalines;
4032.5
4008.9
3970.8
3920.5
3904.8
:
4079.4
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate
p=(1,15,288,289,290,335,336,337,338,351,382,384,385) (0)
(0) q=(1) (48) (336) noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanARIMA_Stepwise_6.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```

Lampiran 99. *Output Double Seasonal ARIMA pada Window 6 dengan Seleksi Input Stepwise.*

Maximum Likelihood Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	-0.16421	0.15233	-1.08	0.2810	1				
MA2,1	0.79351	0.02731	29.06	<.0001	48				
MA3,1	0.99811	38.13593	0.03	0.9791	336				
AR1,1	-0.23714	0.14950	-1.59	0.1127	1				
AR1,2	-0.0059440	0.02658	-0.22	0.8230	15				
AR1,3	0.05169	0.02950	1.75	0.0798	288				
AR1,4	0.0032126	0.03054	0.11	0.9162	289				
AR1,5	-0.0080279	0.02874	-0.28	0.7800	290				
AR1,6	-0.01089	0.02983	-0.37	0.7150	335				
AR1,7	0.0040524	0.06511	0.06	0.9504	336				
AR1,8	-0.06508	0.03095	-2.10	0.0355	337				
AR1,9	-0.14205	0.02755	-5.16	<.0001	338				
AR1,10	-0.0087424	0.03011	-0.29	0.7715	351				
AR1,11	-0.01038	0.02713	-0.38	0.7020	382				
AR1,12	0.0037066	0.02987	0.12	0.9012	384				
AR1,13	-0.06755	0.02773	-2.44	0.0149	385				
Variance Estimate			1522.464						
Std Error Estimate			39.01877						
AIC			11280.67						
SBC			11360.06						
Number of Residuals			1055						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.021	-0.008	0.070	0.035	0.047	0.077
12	.	0	.	-0.042	-0.014	0.019	0.063	0.054	-0.039
18	36.16	2	<.0001	-0.035	0.062	-0.013	-0.015	-0.034	-0.043
24	49.85	8	<.0001	-0.034	-0.066	-0.055	-0.047	-0.044	0.003
30	60.11	14	<.0001	-0.006	0.049	0.024	0.033	0.013	0.072
36	64.72	20	<.0001	-0.011	0.019	-0.002	-0.051	0.012	0.031
42	72.12	26	<.0001	-0.043	-0.004	-0.027	-0.002	0.018	-0.062
48	90.99	32	<.0001	-0.055	-0.005	-0.040	-0.077	0.037	-0.071

Lampiran 100. *Syntax Double Seasonal ARIMA pada Window 7 dengan Seleksi Input Stepwise.*

```

data listrik;
input y;
datalines;
4080.7
4033.9
4013.4
3967.9
3926.3
:
4171.4
;
proc arima data=listrik;
  identify var=y(1,48,336);
  run;
  estimate
p=(1,15,288,289,290,335,336,337,338,351,382,384,385) (0)
(0) q=(1) (48) (336) noconstant method=ml;
  forecast out=ramalan lead=48;
  run;
proc export data=work.ramalan
  outfile="d:\ramalanARIMA_Stepwise_7.xls"
  dbms=excel97
  replace;
  sheet="1";
  run;

```


Lampiran 101. *Output Double Seasonal ARIMA pada Window 7 dengan Seleksi Input Stepwise.*

Maximum Likelihood Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	-0.09586	0.14716	-0.65	0.5148	1				
MA2,1	0.74577	0.02675	27.88	<.0001	48				
MA3,1	0.99991	578.11105	0.00	0.9986	336				
AR1,1	-0.19149	0.14406	-1.33	0.1838	1				
AR1,2	-0.0072910	0.02733	-0.27	0.7897	15				
AR1,3	0.08604	0.03003	2.87	0.0042	288				
AR1,4	-0.02507	0.03154	-0.79	0.4267	289				
AR1,5	-0.01447	0.02887	-0.50	0.6163	290				
AR1,6	-0.04178	0.03156	-1.32	0.1856	335				
AR1,7	0.03831	0.06818	0.56	0.5742	336				
AR1,8	-0.09129	0.03129	-2.92	0.0035	337				
AR1,9	-0.14893	0.02854	-5.22	<.0001	338				
AR1,10	-0.02046	0.03106	-0.66	0.5100	351				
AR1,11	-0.01627	0.02777	-0.59	0.5580	382				
AR1,12	0.03577	0.03160	1.13	0.2576	384				
AR1,13	-0.07143	0.02903	-2.46	0.0139	385				
Variance Estimate				1617.267					
Std Error Estimate				40.21526					
AIC				11315.33					
SBC				11394.71					
Number of Residuals				1055					
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.013	-0.009	0.060	0.037	0.045	0.071
12	.	0	.	-0.039	-0.015	0.010	0.057	0.049	-0.043
18	33.06	2	<.0001	-0.037	0.063	-0.005	-0.018	-0.040	-0.045
24	47.13	8	<.0001	-0.038	-0.060	-0.050	-0.047	-0.056	-0.007
30	57.91	14	<.0001	-0.005	0.049	0.023	0.022	0.015	0.079
36	60.77	20	<.0001	-0.012	0.019	-0.008	-0.039	0.002	0.023
42	67.11	26	<.0001	-0.022	-0.005	-0.034	-0.002	0.025	-0.059
48	80.73	32	<.0001	-0.053	0.003	-0.024	-0.071	0.032	-0.052

Lampiran 102. Surat Pernyataan Data Tugas Akhir.



PT PLN (PERSERO)
PUSAT PENGATUR BEBAN JAWA BALI
AREA PENGATUR BEBAN JAWA TIMUR

Jl. Suningrat No. 45 Taman, Sidoarjo 61257
 Telepon : (031) 7882113, 7882114

Faksimile : (031) 7881024

Nomor : 0073 /SDM.04.09/APB JATIM/ 2016 03 November 2016
 Lampiran :
 Perihal : Bantuan Data untuk Tugas Akhir

Kepada :

INSTITUT TEKNOLOGI SEPULUH NOPEMBER
 FAKULTAS MATEMATIKA DAN ILMU
 PENGETAHUAN ALAM
 JURUSAN STATISTIKA

Di
 SURABAYA

Menunjuk surat Saudara nomor : 064263/IT2.1.1.3/TU.00.09/2016 Tanggal : 13 Oktober 2016 Perihal : Permohonan ijin memperoleh data untuk Tugas Akhir, dengan ini diberitahukan bahwa kami tidak keberatan untuk memberikan ijin kepada Mahasiswa Saudara, bernama :

Nama : Naysila Sintyaningrum
NRP : 1313100025
Program Studi : Sarjana (S1)
Jurusan : Statistika FMIPA

Untuk mendapatkan data serta pada PT. PLN (Persero) P2B Area Pengatur Beban Jawa Timur di Bidang OPERASI SISTEM, dengan persyaratan sebagai berikut :

1. Mahasiswa tersebut diatas supaya mengisi dan menanda tangani Surat Pernyataan 1 (satu) lembar bermeterai Rp. 6.000,-
2. Mahasiswa yang bersangkutan agar mematuhi peraturan/ketentuan yang berlaku di PT. PLN (Persero) sehingga faktor-faktor kerahasiaan harus benar-benar diutamakan.
3. Semua biaya perjalanan, penginapan, makan dan lain sebagainya tidak menjadi tanggungan PT. PLN (Persero) P2B Area Pengatur Beban Jawa Timur.
4. Buku Laporan Kerja Praktek Mahasiswa tersebut agar dikirimkan kepada PT. PLN (Persero) P2B Area Pengatur Beban Jawa Timur 1 (satu) buah.
5. Untuk informasi lebih lanjut dapat menghubungi PT. PLN (Persero) P2B Area Pengatur Beban Jawa Timur Bidang ADMINISTRASI & UMUM.

Demikian harap maklum dan terima kasih atas perhatian saudara.

MANAJER



MUNAWWAR FURQAN

BIODATA PENULIS



Penulis memiliki nama lengkap Naysila Sintyaningrum atau biasa dipanggil dengan nama Nay. Penulis lahir di Karanganyar pada tanggal 26 Februari 1996. Penulis merupakan anak pertama dari pasangan Bapak Mardi dan Ibu Sri Wahyuni. Penulis menempuh pendidikan SD di SD Negeri 02 Jatipurwo sedangkan pendidikan SMP di SMP Negeri 1 Jatipuro. Kemudian penulis menempuh pendidikan SMA di SMA Negeri 1 Sukoharjo. Hingga akhirnya pada tahun 2013 penulis melanjutkan pendidikan di jenjang perguruan tinggi di jurusan Statistika ITS melalui jalur SNMPTN Undangan. Selama 3,5 tahun berkuliah di jurusan Statistika ITS, penulis juga aktif di beberapa organisasi, antara lain adalah SCC HIMASTA-ITS 14/15, FORSIS-ITS 14/15, DPM FMIPA ITS 14/15, SCC HIMASTA-ITS 15/16, dan FORSIS-ITS 15/16. Selama aktif di organisasi tersebut dan kepanitiaan, penulis pernah menjabat sebagai Staff Ahli SCC HIMASTA-ITS 15/16, Wakil Ketua Departemen Jaringan FORSIS-ITS 15/16, Ketua Tim Soal STATION 2015, Ketua Tim Soal DAC 2015. Segala kritik dan saran serta diskusi lebih lanjut mengenai Tugas Akhir ini dapat dikirimkan melalui surat elektronik (*e-mail*) ke alamat naysilasintya@gmail.com atau nomor telepon 087735165833.